



BAB II

TINJAUAN LITERATUR

2.1 Pendahuluan

Model deteksi objek modern seperti YOLO11 memiliki peran penting dalam pengembangan sistem pengenalan penyakit pada tanaman jagung karena kemampuannya melakukan deteksi secara cepat (*real-time*) dan akurat. Arsitektur YOLOv11 dirancang untuk meningkatkan efisiensi ekstraksi fitur melalui mekanisme *backbone* dan *head* yang telah dioptimalkan sehingga model mampu mengenali pola kerusakan pada daun secara lebih presisi. Penelitian terbaru menunjukkan bahwa pemanfaatan YOLOv11 dalam domain pertanian mampu memberikan peningkatan performa dibandingkan versi sebelumnya. Bahwa YOLO11 yang dimodifikasi mampu meningkatkan kinerja deteksi penyakit pada daun jagung secara signifikan dengan rata-rata mAP@50 mencapai 82%. Hasil ini menunjukkan bahwa integrasi mekanisme *feature enhancement* membantu model mengenali pola halus seperti perubahan warna lesi kecil atau lubang akibat serangan ulat. Studi tersebut juga menegaskan bahwa YOLOv11 memiliki stabilitas lebih baik.

2.3 YOLO (You Only Look Once)

YOLO11 adalah arsitektur *deep learning* untuk deteksi objek yang banyak digunakan pada pengolahan citra pertanian. Model ini bekerja *end-to-end* dengan mengekstraksi fitur pada berbagai skala sehingga mampu mengenali gejala penyakit jagung seperti karat daun, hawar daun, bercak abu, batang busuk, secara cepat dan akurat dibandingkan generasi sebelumnya.




Hak Cipta Dilindungi Undang-Undang

1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
Penggunaan untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
2. Penggunaan tanpa izin untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.
Plagiarisme juga dilarang dan dapat dikenakan sanksi.
3. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Hak Cipta Dilindungi Undang-Undang

YOLO11 lebih efisien secara komputasi, lebih stabil saat *training*, dan lebih baik dalam mendeteksi objek kecil di lapangan melalui tiga inovasi utama pada ekstraksi fitur. Beberapa penelitian juga mengembangkan modifikasi berbasis YOLO, seperti RDW-YOLO, yang menambahkan modul ekstraksi fitur khusus sehingga mampu meningkatkan deteksi objek kecil dan gejala awal kerusakan daun [3].



Gambar 2.1: Arsitektur YOLO11 (You Only Look Once)

Tabel 2.1 Penggunaan metode YOLO 11 berbagai objek penelitian

Tujuan	Objek	Akurasi	Kelas	No ref
Deteksi	Buah Kopi	62,3%.	3	[6]
Deteksi	Tomat	87,3%	6	[7]
Optimasi	Pejalan Kaki	83.2%	1	[8]
Deteksi	Apel	83.5%	3	[9]
Klasifikasi	Bilah Bambu	81.8%	6	[10]

Berdasarkan berbagai penelitian pada Tabel 2.1 menunjukkan bahwa model YOLO mampu memberikan performa deteksi penyakit tanaman secara efisien meskipun pada citra dengan kondisi visual yang bervariasi. Penelitian ini

Universitas Islam Indragiri

menegaskan bahwa kemampuan ekstraksi fitur YOLO cukup baik untuk mendeteksi pola penyakit pada tanaman yang memiliki tekstur kompleks [6].

Penelitian ini menunjukkan bahwa metode YOLOv11 mampu meningkatkan deteksi tingkat kematangan buah tomat secara *real-time*. Model berhasil mengenali enam kategori kematangan buah tomat dengan baik. Penambahan modul peningkatan fitur juga meningkatkan akurasi deteksi pada lingkungan yang kompleks, sehingga performa model lebih baik dibandingkan YOLOv11 dasar dan layak digunakan untuk otomatisasi pemantauan serta pemanenan buah tomat [7].

Pada konteks berbeda YOLO11 *improved* sebagai solusi untuk pendeteksian pejalan kaki pada lingkungan padat. Integrasi C3K2 *lighter triplet attention* terbukti meningkatkan performa dalam menangani objek kecil serta kasus *occlusion*. Temuan ini memperlihatkan bahwa penguatan modul-modul internal YOLO11 dapat meningkatkan sensitivitas model terhadap objek kecil, suatu karakteristik yang juga relevan pada deteksi objek tanaman [8].

Selanjutnya mengembangkan YOLO WAS untuk deteksi apel multispesies dan menghasilkan peningkatan akurasi yang signifikan melalui penerapan modul C2PSA SCSA. Optimalisasi ini menekankan bahwa kombinasi *wavelet transform* dan mekanisme perhatian mampu meningkatkan kestabilan deteksi pada lingkungan kebun yang kompleks [9].

Peran modifikasi YOLO11 dalam industri manufaktur di mana YOLO berhasil meningkatkan pendeteksian cacat bambu dengan memadukan modul TriMAD Conv dan C3k2 AddCGLU. Mekanisme ini meningkatkan sensitivitas model terhadap cacat berukuran kecil maupun memanjang, memberikan bukti



bahwa struktur YOLO11 dapat diadaptasi untuk berbagai jenis objek bertekstur kompleks [10].

Secara keseluruhan hasil penelitian pada Tabel 2.1 menunjukkan bahwa pengembangan dari model dasar YOLO11 umumnya difokuskan pada peningkatan kemampuan model dalam menangani objek kecil, lingkungan kompleks dan variasi visual yang tinggi. Hal ini menjadi dasar penting dalam pengembangan metode deteksi objek tanaman termasuk jagung yang juga menghadapi tantangan serupa seperti tekstur daun yang tidak seragam, *occlusion* dan perubahan kondisi lapangan. Untuk memberikan gambaran yang lebih terstruktur mengenai perbandingan performa berbagai pendekatan tersebut, tabel 2.2 ada beberapa penelitian terkait deteksi penyakit dan hama tanaman yang menggunakan metode berbeda.

Tabel 2.2 Deteksi penyakit hama dengan berbagai penelitian

Metode	Objek	Akurasi	No ref
YOLOv5	Tanaman Hama	80.7%	[11]
SSD	Penyakit Daun	73,07%	[12]
K-Means,SVM	Daun Cabai Rawit	82%	[13]

Tabel 2.2 memperlihatkan bahwa metode deteksi penyakit tanaman berbasis citra telah berkembang melalui beragam pendekatan mulai dari *deep learning* modern hingga kombinasi teknik ekstraksi fitur dan klasifikasi. Penelitian menunjukkan bahwa model YOLOv5 memperoleh *mean Average Precision* (mAP) sebesar 80,7%, yang menunjukkan bahwa metode ini mampu melakukan deteksi objek secara cepat dengan tingkat akurasi yang cukup baik. Namun, performanya masih lebih rendah dibandingkan model *ensemble* yang dikembangkan dalam penelitian tersebut [11]. Menggunakan metode *Single Shot Detector* (SSD) untuk mendeteksi penyakit tanaman berdasarkan citra daun menggunakan dataset





PlantVillage yang terdiri atas 38 kelas penyakit dan daun sehat. Model SSD memperoleh *mean Average Precision* (mAP) sebesar 73,07%, yang menunjukkan bahwa metode ini mampu melakukan deteksi penyakit tanaman secara otomatis, namun performanya masih dipengaruhi oleh kompleksitas variasi kelas penyakit dan karakteristik citra yang digunakan. Oleh karena itu, peningkatan metode deteksi masih diperlukan untuk memperoleh akurasi yang lebih tinggi [12].

Metode *image recognition* untuk mendeteksi lima jenis kondisi daun cabai yaitu daun sehat, tungau, kutu kebul, virus kuning, dan bercak daun. Prosesnya meliputi *cropping*, *resizing*, *remove-background*, konversi *grayscale*, selanjutnya dikelompokkan dengan K-Means sebelum diklasifikasi menggunakan SVM. Hasilnya model mencapai akurasi 82% menunjukkan bahwa kombinasi K-Means dan SVM cukup efektif untuk identifikasi awal hama dan penyakit cabai [13].

Secara keseluruhan berbagai penelitian menunjukkan bahwa metode deteksi penyakit tanaman dapat mencapai performa tinggi baik menggunakan *deep learning* maupun teknik ekstraksi fitur. YOLOv5 dan SSD mampu memberikan akurasi serta F1-score yang kuat pada deteksi penyakit daun berbasis citra, terutama pada kelas dengan jumlah data memadai. Sementara itu pendekatan tradisional seperti dikombinasikan dengan K-Means dan SVM juga terbukti efektif pada kondisi tertentu meskipun akurasinya lebih rendah dibandingkan model *deep learning*. Temuan ini menegaskan bahwa metode yang digunakan harus disesuaikan dengan karakteristik data dan tujuan implementasi untuk memperoleh hasil deteksi yang optimal. Untuk memberikan gambaran yang lebih luas mengenai variasi metode yang digunakan pada penelitian sejenis rangkuman berikutnya disajikan pada Tabel 2.3.

1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
2. Penggunaan tanpa izin untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
3. Plagiarisme juga dilarang dan dapat dikenakan sanksi.
3. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Tabel 2.3 Deteksi penyakit hama tanaman jagung dari berbagai metode

Metode	Akurasi	Kelas	No ref
NAÏVE BAYES CLASSIFIER	58.33%	15	[14]
RANDOM FOREST	79.23%	4	[15]
RESNET50	85,13%	8	[16]
YOLOV7	76.3%	13	[17]

Berdasarkan berbagai penelitian pada Tabel 2.3 menunjukkan bahwa metode Naïve Bayes untuk mendeteksi penyakit tanaman jagung berdasarkan 46 gejala yang mewakili 15 jenis penyakit. Sistem meminta pengguna memilih gejala yang muncul kemudian menghitung probabilitas untuk menentukan penyakit paling mungkin. Hasil pengujian menunjukkan kecocokan 18 dari 30 kasus pada lahan pertama dan 17 dari 30 kasus pada lahan kedua dengan akurasi sekitar 60%. Metode ini mampu memberikan deteksi awal namun akurasinya masih rendah sehingga perlu dikombinasikan dengan metode lain agar lebih tepat [14].

Metode berbasis *Machine Learning*, khususnya Random Forest, masih menjadi salah satu pendekatan yang banyak digunakan dalam deteksi penyakit tanaman jagung karena memiliki kemampuan yang baik dalam mengklasifikasikan data berdasarkan hasil ekstraksi fitur serta mampu mengurangi risiko *overfitting* melalui mekanisme *ensemble*. Pendekatan ini menjadi dasar dalam pengembangan sistem deteksi penyakit secara otomatis yang dapat membantu proses identifikasi penyakit jagung secara cepat, akurat, dan efisien, serta berpotensi diterapkan pada berbagai sistem pemantauan pertanian berbasis teknologi [15].

Penelitian ini menggunakan Model berbasis ResNet50 masih menjadi salah satu *backbone* yang banyak digunakan dalam deteksi penyakit dan hama tanaman jagung karena memiliki kemampuan yang baik dalam mengekstraksi fitur citra





secara mendalam dengan tetap mempertahankan efisiensi komputasi. Penggunaan *Residual Network* (ResNet50) mampu mengatasi permasalahan degradasi jaringan pada arsitektur yang semakin dalam melalui mekanisme *skip connection*, sehingga proses ekstraksi fitur menjadi lebih optimal [16].

Penggunaan metode YOLOv7 yang dioptimalkan dengan *optimizer* untuk mendeteksi tiga jenis hama utama jagung yaitu corn borer, armyworm dan *bollworm*. Model ini dirancang untuk meningkatkan akurasi dan stabilitas deteksi pada kondisi lapangan [17].

Penelitian pada Tabel 2.3 metode deteksi penyakit dan hama tanaman jagung memiliki performa yang berbeda-beda. Metode Naïve Bayes hanya mencapai akurasi sekitar 60% sehingga masih kurang optimal untuk proses diagnosis penyakit. Sementara itu, metode berbasis *Machine Learning* seperti Random Forest mampu meningkatkan kemampuan klasifikasi melalui mekanisme *ensemble* sehingga menghasilkan performa yang lebih baik. Di sisi lain, pendekatan berbasis *Deep Learning* seperti ResNet50 memiliki kemampuan yang baik dalam mengekstraksi fitur citra, sedangkan YOLOv7 mampu memberikan hasil deteksi yang lebih cepat, akurat, dan stabil pada kondisi lapangan. Secara umum, setiap metode memiliki kelebihan sesuai dengan karakteristik data dan kebutuhan aplikasi. Untuk memberikan gambaran yang lebih jelas mengenai dataset yang digunakan dalam penelitian ini, maka disajikan Tabel 2.4 sebagai berikut.

1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
2. Penggunaan tanpa izin untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
3. Plagiarisme juga dilarang dan dapat dikenakan sanksi.
3. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Tabel 2.4 Dataset penelitian objek tanaman Jagung

Kelas	Jumlah	Refrensi	No ref
2	3720	Dataset citra daun jagung dari Kaggle	[18]
8	19,451	Dataset langsung di lapangan pertanian	[19]
15	30	Dataset lahan jagung	[14]
38	54.306	Dataset citra penyakit	[12]

Tabel 2.4 menunjukkan bahwa variasi jumlah dan jenis dataset sangat berpengaruh terhadap performa model deteksi penyakit jagung. Dataset besar seperti 3.720 citra daun dari Kaggle memberikan kemampuan generalisasi lebih baik terbukti mampu meningkatkan akurasi metode *Gray Level Co-occurrence Matrix* (GLCM), ANN hingga 99.5% [18]. Sementara itu dataset lapangan berjumlah kecil tetap penting karena mencerminkan kondisi nyata. Pada penelitian KNN berbasis Hue, 30 citra lapangan mampu menghasilkan akurasi 83% meskipun dipengaruhi variasi pencahayaan [19].

Dataset pada penelitian ini berasal dari dinas pertanian kabupaten Bangkalan terdiri dari 46 gejala yang mewakili 15 jenis penyakit jagung. Selain itu digunakan 30 data kasus uji dari dua lokasi lahan untuk mengevaluasi hasil deteksi sistem berbasis Naive Bayes [14].

Dataset tersebut terdiri dari 38 kelas, yang mencakup jenis tanaman jagung. Total dataset berjumlah 54.306 citra, yang kemudian dibagi menjadi 38.017 citra data latih (70%), 10.858 citra data validasi (20%), dan 5.431 citra data uji (10%). Pembagian data tersebut dilakukan untuk melatih, memvalidasi, dan mengevaluasi performa model *deep learning* dalam mengidentifikasi penyakit tanaman [12].

Berdasarkan Tabel 2.4 terlihat bahwa ukuran, sumber, dan karakteristik dataset sangat memengaruhi performa model deteksi penyakit tanaman. Dataset





Hak Cipta Dilindungi Undang-Undang

1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.

2. Penggunaan tanpa izin untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.

3. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

Universitas Islam Indragiri

berukuran besar umumnya mampu meningkatkan kemampuan model dalam mengenali berbagai variasi gejala penyakit sehingga menghasilkan akurasi yang lebih tinggi dibandingkan dataset dengan jumlah citra yang terbatas. Dataset lapangan tetap memiliki nilai penting karena merepresentasikan kondisi nyata, meskipun performa model dapat dipengaruhi oleh variasi pencahayaan, latar belakang, dan kualitas citra. Selain itu, dataset berbasis gejala dari instansi pertanian banyak digunakan pada sistem pakar untuk mendeteksi penyakit berdasarkan gejala yang diamati.

Sementara itu, penelitian ini menggunakan PlantVillage Dataset yang terdiri atas 38 kelas dengan total 54.306 citra yang dibagi menjadi 38.017 data latih (70%), 10.858 data validasi (20%), dan 5.431 data uji (10%). Jumlah data yang besar serta variasi kelas yang lengkap memberikan kemampuan generalisasi yang lebih baik bagi model *deep learning* dalam mengidentifikasi berbagai penyakit tanaman. Secara keseluruhan, pemilihan dataset yang sesuai, baik dari segi jumlah, kualitas, maupun keragaman kelas, menjadi faktor penting dalam meningkatkan efektivitas dan keandalan sistem deteksi penyakit tanaman. Untuk memberikan gambaran yang lebih jelas mengenai penelitian yang digunakan, selanjutnya disajikan Tabel 2.5.

Tabel 2.5 Akurasi penelitian tanaman jagung

Metode	Kelas	Akurasi	Recall	Specif icity	Precis ion	F- 1score	No ref
YOLOV7	13	76.3%	77,3%	96,3%	73,3%	75,2%	[17]
Naive Bayes	15	60%	60%	70%	60%	60%	[14]

Tabel 2.5 menunjukkan bahwa penelitian menggunakan metode YOLOv7, yaitu pengembangan dari algoritma YOLOv7, untuk mendeteksi hama pada tanaman jagung. Dataset yang digunakan berasal dari IP102, dengan memilih 13



kelas hama jagung (IP13) yang terdiri dari 4.533 citra. Dataset dibagi menjadi data latih dan data validasi dengan rasio sekitar 80:20 menggunakan 5-fold *cross-validation*, sehingga diperoleh 3.600 citra data latih dan 932 citra data uji. Hasil pengujian menunjukkan bahwa metode Maize-YOLO memperoleh mAP sebesar 76,3%, serta mampu melakukan deteksi secara *real-time* dengan kecepatan 67 FPS. Hasil tersebut menunjukkan bahwa Maize-YOLO mampu memberikan keseimbangan yang baik antara akurasi, kecepatan deteksi, dan efisiensi komputasi sehingga efektif untuk mendeteksi hama pada tanaman jagung [17].

Naive Bayes menggunakan 46 gejala dari Dinas Pertanian Bangkalan untuk mendeteksi 15 jenis penyakit jagung. Sistem menentukan hasil diagnosis berdasarkan probabilitas kemunculan gejala. Hasil pengujian menunjukkan kecocokan sekitar 60% sehingga metode ini cukup membantu deteksi awal namun belum akurat bila dibandingkan metode berbasis citra [14].

Metode YOLOv7 sangat efektif untuk mendeteksi hama pada tanaman jagung dengan memanfaatkan dataset citra IP13 yang terdiri atas 13 kelas hama. Metode ini mampu mencapai mAP sebesar 76,3% serta memiliki kemampuan deteksi secara *real-time* dengan kecepatan 67 FPS, sehingga memberikan keseimbangan yang baik antara akurasi, kecepatan deteksi, dan efisiensi tingkat kecocokan sekitar 60% sehingga lebih sesuai digunakan sebagai sistem deteksi. Untuk memberikan gambaran yang lebih jelas mengenai metode dan cakupan penelitian yang digunakan, selanjutnya disajikan Tabel 2.6.

1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.

2. Penggunaan tanpa izin untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.

3. Plagiarisme juga dilarang dan dapat dikenakan hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.

3. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.



Tabel 2.6 Akurasi YOLO11 dengan berbagai penelitian

Objek	Kelas	Akurasi	R	S	P	F-1score	No ref
kopi	5	84.54%	77.4%	86.50%	81.1%	79.2%	[18]
Tomat	6	83%	80.3%	88.6%	84.0%	82.2%	[19]
Bawah laut	4	77.4%	70.3%	81,0%	78.8%	74.0%	[20]
menara distribusi listrik	2	80%	0.801%	0.92%	0.886%	84.3%	[21]
Daun kapas	8	77.1%	73.6%	84.2%	81.7%	77.4%	[22]

Pada Tabel 2.6 menunjukkan bahwa Penelitian ini membuktikan bahwa metode YOLOv11 mampu mendeteksi tingkat kematangan buah kopi secara *real-time* dengan performa yang baik pada lima kategori kematangan, yaitu dry, overripe, ripe, semi-ripe, dan unripe. Model memperoleh Hasil evaluasi menunjukkan bahwa model memiliki kemampuan deteksi yang baik terutama pada kategori ripe dan semi-ripe, sedangkan kategori unripe masih memiliki tingkat deteksi yang lebih rendah akibat kemiripan warna dengan latar belakang dan ketidakseimbangan jumlah data. Secara keseluruhan, metode ini efektif digunakan untuk membantu proses pemantauan tingkat kematangan buah kopi secara otomatis [18].

Penelitian ini bahwa metode YOLOv11 mampu meningkatkan kinerja deteksi tingkat kematangan buah tomat secara *real-time* melalui pengembangan arsitektur yang lebih ringan dan efisien. Model berhasil mengenali enam kategori kematangan buah tomat. Hasil penelitian menunjukkan bahwa penambahan modul peningkatan fitur mampu meningkatkan kemampuan deteksi objek pada kondisi



lingkungan yang kompleks sehingga model memiliki performa yang lebih baik dibandingkan YOLOv11 dasar dan layak diterapkan untuk proses otomatisasi pemantauan serta pemanenan buah tomat [19].

Metode YOLOv11 mampu meningkatkan performa deteksi objek bawah laut secara *real-time* melalui penambahan mekanisme perhatian (*attention mechanism*) dan strategi peningkatan fitur multi-skala. Hasil pengujian menunjukkan bahwa metode ini mampu meningkatkan kemampuan deteksi berbagai objek bawah laut, seperti teripang, landak laut, kerang, dan bintang laut, terutama pada kondisi lingkungan yang kompleks, objek berukuran kecil, serta target yang saling berdekatan. Secara keseluruhan, model memiliki performa yang lebih baik dibandingkan YOLOv11 dasar sehingga berpotensi diterapkan pada sistem pemantauan bawah laut secara otomatis [20].

Penelitian ini memperkenalkan TDD-YOLO sebuah pengembangan dari YOLOv11n yang dirancang khusus untuk mendeteksi *defect* berukuran sangat kecil pada infrastruktur distribusi listrik. Model ini menggabungkan modul SPD-Conv, CBAM, BiFPN, serta *detection head* beresolusi 160×160 yang terbukti meningkatkan kemampuan ekstraksi fitur pada objek kecil [21].

YOLO mampu mendeteksi hama dan penyakit daun kapas secara *real-time* dengan performa yang lebih baik dibandingkan YOLOv11 dasar terbukti meningkatkan kemampuan model dalam mendeteksi lesi berukuran kecil, objek yang saling tumpang tindih, serta penyakit pada latar belakang yang kompleks. Meskipun demikian, model masih mengalami keterbatasan pada beberapa jenis penyakit dengan kontras rendah atau bentuk lesi yang tidak beraturan sehingga masih diperlukan pengembangan lebih lanjut melalui penambahan variasi data dan

1. Dilarang memperbanyak atau mendistribusikan dokumen ini untuk tujuan komersial tanpa izin tertulis dari penulis atau pihak berwenang.
 2. Penggunaan tanpa izin untuk kepentingan akademik, penelitian, dan pendidikan diperbolehkan dengan mencantumkan sumber.
 3. Plagiarisme juga dilarang untuk kepentingan komersial atau pelanggaran hak cipta dapat dikenakan sanksi sesuai dengan UU Hak Cipta di Indonesia.
3. Universitas hanya berhak menyimpan dan mendistribusikan dokumen ini di repositori akademik, tanpa mengalihkan hak cipta penulis, sesuai dengan peraturan yang berlaku di Indonesia.

peningkatan mekanisme perhatian (*attention mechanism*). Secara keseluruhan, penelitian ini menunjukkan bahwa RDL-YOLO efektif digunakan untuk sistem deteksi hama dan penyakit tanaman secara otomatis di bidang pertanian [22].

Secara keseluruhan peningkatan modul fitur dan arsitektur deteksi beresolusi tinggi menghasilkan performa *real-time* yang stabil dan akurat meskipun beberapa kelas objek masih memerlukan peningkatan. Seluruh model menunjukkan potensi kuat untuk diterapkan dalam sistem pemantauan otomatis dan manajemen pertanian cerdas. Untuk memberikan gambaran yang lebih jelas serta cakupan yang digunakan pada penelitian ini, berikut disajikan Tabel 2.7 sebagai berikut.

Tabel 2.7 Dataset penyakit tanaman jagung

Dataset	Kelas	Jumlah	No ref
Gejala dan jenis penyakit	15	45	[14]
Gambar daun jagung	8	19.451	[19]
Kaggle	2	3.720	[18]

Tabel 2.7 menunjukkan bahwa setiap metode deteksi penyakit jagung memiliki keunggulan dan batasannya masing-masing. Metode Naive Bayes menggunakan 46 gejala untuk memprediksi 15 jenis penyakit dan menghasilkan akurasi sekitar 60% sehingga lebih cocok untuk deteksi awal berbasis gejala namun kurang akurat pada kondisi lapangan dengan gejala yang saling mirip [14]. Sementara itu dataset lapangan berjumlah kecil tetap penting karena mencerminkan kondisi nyata. Pada penelitian KNN berbasis Hue, 8 citra lapangan meskipun dipengaruhi variasi pencahayaan [19]. Selain itu penelitian oleh Permadi Hidayat menggunakan kombinasi *Gray Level Co-occurrence Matrix* (GLCM) dan ANN *backpropagation* untuk mendeteksi hawar daun jagung berbasis tekstur. Model ini dilatih pada 3.000, 3.720 citra daun dari Kaggle dan mampu mencapai akurasi



99.5% serta *precision* dan *recall* 100%, sehingga sangat efektif untuk mendeteksi pola penyakit yang memiliki ciri tekstur yang kuat [18].

Berdasarkan Tabel 2.7 metode berbasis citra terbukti memberikan performa deteksi penyakit jagung yang jauh lebih akurat dibandingkan pendekatan berbasis gejala. Metode Naive Bayes hanya mencapai akurasi sekitar 60% sehingga kurang efektif untuk kondisi lapangan. Sebaliknya model KNN berbasis Hue mampu mencapai akurasi 90% berkat pemanfaatan citra dan modul perhatian yang lebih adaptif dalam mengenali objek kecil. Pendekatan GLCM, ANN juga menunjukkan performa sangat tinggi dengan akurasi 99.5% serta *precision* dan *recall* 100% sehingga sangat efektif untuk mendeteksi tekstur penyakit yang khas pada daun jagung. Secara keseluruhan metode berbasis citra dan *deep learning* memberikan hasil deteksi yang lebih unggul. Untuk memberikan gambaran yang lebih jelas serta cakupan yang digunakan pada penelitian ini, berikut disajikan Tabel 2.8 sebagai berikut.

Tabel 2.8 Posisi Penelitian Yang Dilakukan

Metode	Kelas	Dataset	Objek	Akurasi	No ref
Navie Bayes Classifier	15	46 Gejala	Jagung	60%	[23]
YOLOV7	13	4.533 citra	Jagung	76.3%	[17]
KNN	4	2.048	Jagung	75.01%	[22][24]
RESNET50	8	2.775	Jagung	78.62%	[16]
YOLO11	5	5000	Jagung	-	-

Berdasarkan Tabel 2.8 metode metode Naive Bayes untuk mendeteksi penyakit tanaman jagung berdasarkan 46 gejala yang mewakili 15 jenis penyakit dan diuji menggunakan 30 kasus dari dua lokasi lahan. Sistem menentukan penyakit



berdasarkan probabilitas kemunculan gejala yang dipilih pengguna. Hasil pengujian menunjukkan kecocokan [23].

Penelitian ini menggunakan metode *Color moments* dan *Gray Level Co-occurrence Matrix* (GLCM) untuk mengekstraksi fitur warna dan tekstur daun jagung lalu diklasifikasikan menggunakan KNN. Dataset terdiri dari 160 citra yang terbagi dalam empat kelas yaitu daun sehat, hawar daun, bercak daun, dan karat daun. Hasil pengujian menunjukkan akurasi tertinggi 89.375% pada nilai k1 dengan *Euclidean Distance* sehingga metode ini cukup efektif untuk deteksi penyakit daun jagung berbasis citra [17].

Penelitian ini menggunakan metode YOLO, yaitu pengembangan dari algoritma YOLOv7, untuk mendeteksi hama pada tanaman jagung. Dataset yang digunakan merupakan IP13, yaitu subset dari IP102, yang terdiri atas 4.533 citra dengan 13 kelas hama jagung [22]. Hasil pengujian menunjukkan bahwa model YOLO mampu melakukan deteksi secara *real-time* dengan kecepatan 67 FPS, sehingga metode ini efektif digunakan untuk mendeteksi hama pada tanaman jagung secara akurat dan efisien [24].

Model ResNet50 digunakan untuk mengklasifikasikan penyakit pada tanaman jagung menggunakan dataset citra yang telah melalui proses pelatihan, validasi, dan pengujian. Arsitektur ResNet50 dengan konsep *residual learning* mampu mengekstraksi fitur citra secara mendalam sehingga meningkatkan kemampuan model dalam membedakan berbagai kelas penyakit. Hasil pengujian menunjukkan bahwa model ResNet50 memperoleh nilai akurasi yang tinggi serta mampu mengklasifikasikan penyakit jagung secara efektif. Dengan kemampuan ekstraksi fitur yang baik, ResNet50 menjadi salah satu metode *deep learning* yang



andal untuk mendukung proses identifikasi penyakit tanaman jagung secara otomatis [16].

Berdasarkan Tabel 2.8 terlihat bahwa setiap metode memiliki kemampuan yang berbeda dalam mendeteksi penyakit dan objek pada tanaman jagung. Metode Naive Bayes hanya mampu mencapai akurasi sekitar 60% sehingga kurang akurat ketika diterapkan pada kondisi lapangan yang kompleks. Pendekatan berbasis citra seperti *color moments* dan YOLOv7 memberikan hasil akurasi 76.3% [24]. Sebaliknya ResNet50 dengan arsitektur yang ditingkatkan mampu mencapai akurasi 78.62% [25].

Melalui perbandingan tersebut dapat disimpulkan bahwa YOLO11 merupakan pilihan metode yang paling tepat untuk digunakan dalam penelitian, karena merupakan pengembangan terbaru dari keluarga YOLO dengan peningkatan signifikan pada deteksi objek kecil, efisiensi komputasi, serta kemampuan generalisasi di kondisi lapangan yang beragam. YOLO11 jauh lebih stabil dan akurat dibandingkan metode tradisional seperti Naive Bayes dan KNN maupun model sebelumnya seperti YOLOv5, YOLOv6, YOLOv7, dan YOLOv8. Keunggulannya dalam kecepatan inferensi, ketahanan terhadap perubahan pencahayaan serta akurasi tinggi menjadikan YOLO11 sangat cocok untuk diterapkan pada deteksi penyakit, hama, maupun organ tanaman jagung secara *real-time*. Dengan demikian penggunaan YOLO11 sebagai metode penelitian memberikan dasar yang kuat untuk mencapai hasil deteksi yang lebih optimal [26].

