



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

BAB II

TINJAUAN LITERATUR


Bab ini menguraikan teori-teori, konsep dasar, dan hasil penelitian terdahulu yang relevan dengan pengembangan model hybrid CNN–SVM untuk klasifikasi tingkat kematangan buah nanas. Tinjauan literatur ini bertujuan untuk memberikan landasan ilmiah serta memperlihatkan posisi penelitian ini di antara penelitian sebelumnya.

2.1 Convolutional Neural Networks (CNN)

Convolutional Neural Network (CNN) merupakan salah satu model deep learning yang paling banyak digunakan dalam pengolahan citra karena kemampuannya mengekstraksi fitur visual secara otomatis melalui lapisan konvolusi dan pooling. CNN bekerja dengan mengenali pola penting pada gambar seperti bentuk, warna, tepi, dan tekstur sehingga model mampu melakukan klasifikasi secara lebih akurat. Berbagai penelitian telah menunjukkan bahwa performa CNN dapat meningkat secara signifikan melalui proses optimasi. Sebagai contoh, penggunaan optimizer ADAM pada CNN terbukti mampu meningkatkan akurasi hingga 98,50% dalam klasifikasi citra daging sapi setelah dilakukan penyesuaian terhadap parameter learning rate[6]

Selain itu, sejumlah penelitian mengembangkan bentuk arsitektur CNN baru yang dirancang untuk meningkatkan performa pada objek citra tertentu. Misalnya, modifikasi struktur CNN pada penelitian FD-CNN menunjukkan bahwa model dapat meningkatkan ketajaman ekstraksi fitur pada citra daun herbal sehingga menghasilkan klasifikasi yang lebih akurat [7] CNN juga diterapkan secara luas pada berbagai bidang seperti kesehatan, pertanian, dan identifikasi objek. Bahkan

integrasi CNN dengan jaringan berurutan seperti RNN telah digunakan untuk pendeteksian COVID-19, di mana CNN mengekstraksi fitur visual sebelum diproses oleh RNN [8]. Dengan kemampuannya mempelajari representasi yang kompleks, CNN menjadi metode yang sangat unggul dalam klasifikasi citra termasuk dalam analisis kematangan buah, yang memiliki variasi warna dan tekstur cukup signifikan.



Gambar 2. 1 Arsitektur metode Convolutional Neutral Network(CNN)

2.2 Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah algoritma klasifikasi yang bekerja dengan mencari *hyperplane* yang memisahkan kelas data secara optimal melalui margin yang paling lebar. Menurut Huang (2023), SVM memiliki “kemampuan klasifikasi non-linear yang kuat dan robust terhadap data yang bising”, terutama ketika menggunakan kernel seperti Radial Basis Function (RBF) untuk memetakan data ke ruang dimensi lebih tinggi[9]. Pada penelitian tersebut SVM dikombinasikan dengan PCA untuk mengurangi dimensi fitur da mampu mencapai akurasi 90%






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.

pada klasifikasi citra buah, menunjukkan bahwa SVM bekerja optimal ketika fitur yang digunakan lebih sederhana dan informatif.

Selain itu, penelitian Sutisna et al. (2024) menunjukkan bahwa performa SVM sangat bergantung pada fitur yang dipilih, di mana penggunaan metode seleksi fitur RFE meningkatkan akurasi klasifikasi tanaman rimpang hingga 81% [10]. Berbagai studi lain juga menunjukkan bahwa SVM sering digunakan dalam kombinasi dengan model ekstraksi fitur seperti CNN untuk meningkatkan akurasi. Misalnya, penelitian terkait optimasi model *hybrid* CNN-SVM pada objek buah tertentu berhasil mencapai akurasi hingga 99,12%, menunjukkan bahwa SVM sangat efektif sebagai classifier akhir pada data visual berdimensi tinggi [11].



Gambar 2. 2 Arsitektur Model Super Vector Machine (SVM)

2.3 Model *Hybrid* CNN-SVM

Penelitian ini menggunakan kombinasi Convolutional Neural Network (CNN) dan Support Vector Machine (SVM) karena kedua metode memiliki keunggulan yang saling melengkapi dalam klasifikasi citra. CNN berfungsi mengekstraksi fitur visual secara otomatis, seperti warna, tekstur, dan bentuk objek, sedangkan SVM digunakan sebagai classifier karena mampu membentuk

hyperplane optimal (*maximum margin*) sehingga dapat memisahkan kelas dengan karakteristik visual yang berdekatan secara lebih baik. Kombinasi CNN sebagai *feature extractor* dan SVM sebagai *classifier* diharapkan menghasilkan model yang lebih stabil serta memiliki kemampuan generalisasi yang lebih baik dibandingkan penggunaan CNN dengan lapisan Softmax saja.

Hal tersebut didukung oleh penelitian [25] yang menunjukkan bahwa model Hybrid CNN-SVM mampu memberikan performa klasifikasi yang baik pada citra buah, dengan CNN sebagai pengekstraksi fitur dan SVM sebagai algoritma klasifikasi akhir. Berdasarkan penelitian tersebut, penggunaan Hybrid CNN-SVM pada penelitian ini tidak hanya bertujuan memperoleh akurasi yang tinggi, tetapi juga memanfaatkan peran masing-masing algoritma yang saling melengkapi dalam mengklasifikasikan lima tingkat kematangan buah nanas. Beberapa penelitian sebelumnya juga telah melakukan optimasi berbagai model pembelajaran mesin dan *deep learning* untuk meningkatkan performa klasifikasi melalui penyesuaian parameter maupun penggunaan algoritma tertentu [26]. Ringkasan penelitian terkait optimasi model disajikan pada tabel berikut.

Tabel 2. 1 Optimasi Model Pada Berbagai Penelitian

Model Utama	Metode Optimasi	Parameter	Akurasi	Objek	Ref.
CNN	ADAM	<i>Learning rate</i>	98,50%	Daging sapi	[6]
SVM	RFE	Fitur	81,00%	Tanaman rimpang	[10]
SVM	<i>Metaheuristic & Statistical Techniques</i>	Regularisasi, <i>gamma</i>	91,69%	Tutupan lahan	[12]
Hybrid CNN-SVM	GA & NSGA-II	Filter CNN, kernel SVM	99,12%	Buah	[9]



SVM	<i>Grid Search</i>	Kernel, <i>cost</i> , <i>gamma</i>	98,00%	Buah kopi	[13]
KNN	<i>Backward Elimination</i>	Fitur	97,60%	Penyakit diabetes	[11]

Tabel 2.1 menampilkan berbagai penelitian yang berfokus pada optimasi model pembelajaran mesin dan deep learning dalam meningkatkan akurasi klasifikasi citra. Berdasarkan tabel tersebut, terlihat bahwa setiap metode optimasi berkontribusi secara signifikan terhadap peningkatan performa model. Misalnya, penggunaan algoritma ADAM pada model CNN terbukti mampu menghasilkan akurasi yang sangat tinggi, yaitu 98,50% pada objek daging sapi, menunjukkan bahwa optimasi parameter seperti *learning rate* berpengaruh besar terhadap stabilitas proses pelatihan jaringan saraf konvolusional [6].

Sementara itu, penelitian lainnya menunjukkan bahwa Support Vector Machine (SVM) juga sangat bergantung pada pemilihan fitur dan parameter regulasi. Metode seperti Recursive Feature Elimination (RFE) digunakan untuk memilih fitur yang paling relevan sehingga meningkatkan akurasi menjadi 81% pada objek tanaman rimpang [10]. Temuan tersebut diperkuat oleh penelitian yang menerapkan teknik metaheuristik dan statistik pada SVM, yang berhasil mengoptimalkan parameter regularization dan gamma sehingga mencapai akurasi 91,69% dalam klasifikasi tutupan lahan [12].

Model *hybrid* CNN–SVM menjadi salah satu pendekatan paling menjanjikan dalam tabel ini. Penelitian yang menggabungkan Genetic Algorithm (GA) dan NSGA-II untuk mengoptimalkan filter CNN dan kernel SVM berhasil melaporkan akurasi mencapai 99,12% pada objek buah, yang merupakan nilai tertinggi pada tabel [9]. Hasil ini menunjukkan bahwa



optimasi berbasis algoritma evolusioner sangat efektif dalam meningkatkan kinerja model *hybrid* pada data citra kompleks. Selain itu, metode optimasi berbasis grid search pada SVM juga menunjukkan hasil yang baik pada klasifikasi buah kopi, dengan akurasi mencapai 98% [13]. Tidak hanya pada SVM atau CNN, pendekatan optimasi fitur juga efektif diterapkan pada algoritma lain seperti K-Nearest Neighbor (KNN). Penelitian yang menggunakan metode Backward Elimination pada KNN menunjukkan peningkatan akurasi menjadi 97,60% dalam klasifikasi penyakit diabetes [11]. Hal ini menegaskan bahwa pemilihan fitur yang tepat memainkan peran penting dalam kinerja berbagai algoritma klasifikasi.

Dengan melihat tingginya efektivitas berbagai metode optimasi pada Tabel 2.1, dapat disimpulkan bahwa peningkatan performa model sangat dipengaruhi oleh pemilihan strategi optimasi yang tepat. Namun, selain optimasi parameter, perkembangan model berbasis *deep learning* juga menunjukkan arah baru dalam meningkatkan kualitas klasifikasi citra, khususnya melalui pendekatan *hybrid*. Oleh karena itu, untuk memberikan gambaran yang lebih komprehensif mengenai evolusi model CNN dalam berbagai penelitian, Seiring dengan meningkatnya kebutuhan akan metode klasifikasi citra yang lebih akurat dan efisien, berbagai penelitian mulai mengembangkan model berbasis CNN yang dikombinasikan dengan algoritma lain untuk membentuk arsitektur *hybrid*. Pendekatan ini muncul dari keterbatasan CNN yang meskipun unggul dalam ekstraksi fitur visual, namun masih membutuhkan *classifier* yang lebih kuat untuk meningkatkan ketepatan keputusan akhir. Oleh karena itu, integrasi CNN dengan berbagai



algoritma seperti SVM, RNN, maupun LSTM menjadi tren baru dalam penelitian klasifikasi citra modern.

Tabel 2.2 berikut menyajikan beberapa contoh penerapan model hybrid CNN pada berbagai objek penelitian, yang menunjukkan bagaimana kombinasi metode ini dapat meningkatkan akurasi, stabilitas, dan performa keseluruhan sistem klasifikasi. Penerapan model *hybrid* ini membuktikan bahwa penggabungan kemampuan ekstraksi fitur CNN dengan kemampuan pengklasifikasian model lain dapat menghasilkan kinerja yang lebih unggul dibandingkan penggunaan metode tunggal.

Tabel 2. 2 Penggunaan Model Hybrid CNN berbagai Objek Penelitian

Model Hybrid	Tujuan	Objek	No Ref
FD-CNN	Meningkatkan akurasi klasifikasi	Daun herbal	[7]
CNN- SVM	mMeningkatkan akurasi klasifikasi	gulma(weed)	[14]
CNN- RNN	Implementasi deep learning	COVID-19	[8]
<i>Hybrid</i> CNN– LSTM	Deteksi	NSL-KDD, KDDCup99, CIC-IDS2018, ISCX2012	[15]

Dari hasil yang ditampilkan pada Tabel 2.2, terlihat bahwa penerapan model *hybrid* CNN pada berbagai objek penelitian memberikan kontribusi signifikan dalam peningkatan performa klasifikasi. Penelitian mengenai FD-CNN menunjukkan bahwa modifikasi struktur CNN mampu meningkatkan akurasi identifikasi daun herbal secara substansial, terutama karena fitur-fitur penting dapat diekstraksi dengan lebih tajam dibandingkan metode konvensional[7]. Hal ini menandakan bahwa pengembangan arsitektur CNN



terus berevolusi untuk menyesuaikan kebutuhan analisis citra yang semakin kompleks.

Pada penelitian lain, integrasi CNN–SVM terbukti memberikan performa yang lebih optimal untuk klasifikasi objek seperti gulma. CNN digunakan sebagai pengambil fitur visual mendalam, sementara SVM mengoptimalkan proses pengambilan keputusan melalui margin klasifikasi yang lebih stabil [14]. Kombinasi ini menunjukkan bahwa menggabungkan kekuatan ekstraksi fitur CNN dengan efisiensi pengklasifikasian SVM dapat menghasilkan sistem klasifikasi yang lebih akurat dan robust pada data dengan tekstur tidak teratur.

Sementara itu, model *hybrid* CNN–RNN banyak dimanfaatkan pada bidang medis, seperti pendeteksian COVID-19. CNN bekerja mengekstraksi pola visual dari citra medis, sedangkan RNN mengolah hubungan temporal atau pola berurutan yang muncul dalam data, sehingga memberikan hasil klasifikasi yang lebih akurat dan sensitif terhadap variasi data [8]. Studi ini menegaskan peran penting metode *hybrid* dalam domain diagnosis penyakit yang membutuhkan analisis citra tingkat lanjut.

Model *hybrid* CNN–LSTM juga memiliki peran strategis dalam penelitian berbasis data sekuensial, khususnya pada sistem deteksi serangan siber. CNN memproses fitur spasial dari data trafik jaringan, sementara LSTM mampu menangkap pola temporal yang berkesinambungan sehingga meningkatkan akurasi dalam deteksi berbagai jenis serangan [15]. Hasil penelitian tersebut menunjukkan bahwa penggabungan metode ini sangat efektif untuk aplikasi yang membutuhkan analisis dinamis dalam data berurutan.



Secara keseluruhan, penelitian-penelitian pada Tabel 2.2 memperlihatkan bahwa model *hybrid* CNN merupakan solusi yang adaptif dan efisien untuk permasalahan klasifikasi citra pada berbagai domain. Kombinasi CNN dengan teknik lain terbukti memperluas kemampuan model dalam memahami variasi data yang kompleks, sekaligus meningkatkan performa sistem secara keseluruhan.

Melihat berbagai hasil penelitian pada Tabel 2.2, tampak bahwa pendekatan *hybrid* CNN memiliki potensi besar dalam meningkatkan performa sistem klasifikasi di berbagai domain, baik pada pengolahan citra medis, identifikasi objek, maupun deteksi pola sekuensial yang kompleks. Keunggulan ini terutama karena kemampuan CNN dalam menghasilkan representasi fitur visual yang kuat, yang kemudian dipadukan dengan algoritma lain untuk memperkuat proses pengambilan keputusan akhir.

Salah satu kombinasi yang paling menonjol dan banyak digunakan adalah *hybrid* CNN–SVM, yang mengintegrasikan keunggulan CNN dalam mengekstraksi fitur dengan stabilitas SVM dalam melakukan klasifikasi non-linear. Untuk memberikan gambaran lebih komprehensif mengenai efektivitas penerapan model ini, Tabel 2.3 berikut merangkum berbagai penelitian yang menggunakan *hybrid* CNN–SVM pada beragam objek dan konteks penelitian.

Tabel 2. 3 Penggunaan Model Hybrid CNN-SVM berbagai penelitian

Tujuan penelitian	Objek	Akurasi	No Ref
Klasifikasi	Lukisan	93,28%	[16]
Kalsifikasi	Penyakit Tumor	98.92%	[17]
Klasifikasi	Biji kako	98,32%	[18]
Prediksi	Tebu	89,53%	[19]





Berdasarkan hasil yang tersaji pada Tabel 2.3, terlihat bahwa pendekatan *hybrid* CNN–SVM terus menunjukkan performa unggul dalam berbagai bidang penerapan, khususnya pada klasifikasi citra dan analisis data semi-terstruktur. Penelitian pada klasifikasi biji kakao, misalnya, membuktikan bahwa penggunaan CNN sebagai *feature extractor* dan SVM sebagai *final classifier* menghasilkan akurasi yang lebih tinggi dibandingkan penggunaan CNN atau SVM secara tunggal [16]. Hal ini disebabkan oleh kemampuan CNN dalam mengekstraksi fitur citra yang lebih dalam dan representatif, sementara SVM memberikan batas keputusan yang lebih optimal pada ruang fitur berdimensi tinggi.

Selain itu, pada penelitian lain di bidang pertanian presisi, model *hybrid* CNN–SVM digunakan untuk memproses data pertanian semi-terstruktur dan memprediksi parameter lingkungan penting seperti kelembapan tanah. Dengan menggabungkan kekuatan CNN dalam analisis pola visual dan keandalan SVM dalam klasifikasi non-linear, penelitian tersebut berhasil meningkatkan akurasi prediksi hingga melampaui model-model sebelumnya [17]. Hasil ini menegaskan bahwa *hybrid* model tidak hanya relevan pada pengolahan citra, tetapi juga pada data sensor dan data berbasis waktu. Dalam bidang perkebunan, model *hybrid* juga dimanfaatkan untuk meningkatkan efektivitas klasifikasi hasil panen dan data agrikultur dengan memadukan CNN untuk identifikasi ciri-ciri visual serta SVM untuk klasifikasi. Hasil akhir studi-studi tersebut menunjukkan bahwa pendekatan *hybrid* mampu memberikan kinerja yang lebih stabil dalam kondisi data yang bervariasi dan tidak terstruktur [18]. Keunggulan ini menjadi alasan utama mengapa kombinasi CNN–SVM terus

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. 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.



Lebih lanjut, penelitian mengenai prakiraan produksi tanaman tebu juga mengonfirmasi efektivitas penggabungan CNN dan SVM. Dengan memanfaatkan CNN untuk mengekstraksi pola pada data pertanian dan SVM untuk memproses hasil ekstraksi tersebut, model *hybrid* terbukti menghasilkan tingkat akurasi yang lebih baik dibandingkan model prediksi konvensional lainnya [19]. Hal ini menunjukkan bahwa pendekatan *hybrid* mampu mengatasi keterbatasan model tunggal, terutama dalam mengolah data beragam dan kompleks.

Secara keseluruhan, temuan-temuan dalam Tabel 2.3 memperlihatkan bahwa model hybrid CNN–SVM menjadi solusi komputasi yang efisien dan adaptif pada beragam konteks penelitian. Kekuatan utamanya terletak pada kombinasi antara kemampuan CNN dalam membangun representasi fitur mendalam dan keandalan SVM dalam menghasilkan klasifikasi yang presisi. Hasil-hasil tersebut menjadi dasar kuat untuk melanjutkan pembahasan menuju model hybrid lainnya yang akan diuraikan pada tabel berikutnya.

Tabel 2. 4 Penelitian objek buah nanas dengan berbagai metode

Tujuan Penelitian	Metode	Akurasi	Kelas	No Ref
Mendeteksi	YOLOv2 berbasis CNN	99.27%	4	[20]
Klasifikasi	CNN	86%	2	[21]
Klasifikasi	deep learning berbasis CNN	86,75	4	[22]
Ekstrasi Fitur	RGB	86,05%	3	[23]
Klasifikasi	SVM	65,59%	3	[24]

Hasil perbandingan beberapa penelitian pada Tabel 2.4 menunjukkan bahwa pendekatan klasifikasi tingkat kematangan buah nanas terus

berkembang, baik melalui metode berbasis computer vision, machine learning, maupun deep learning. Setiap penelitian memiliki fokus dan kontribusi yang berbeda, mulai dari pengolahan citra sederhana hingga penerapan model berbasis jaringan saraf yang lebih kompleks.

Penelitian oleh Liandaputra dan Zahra [20] menunjukkan bahwa penggunaan arsitektur CNN modern seperti MobileNetV2 mampu mencapai akurasi tinggi hingga 93% untuk empat kelas kematangan buah nanas. Hal ini menegaskan bahwa model ringan (lightweight) berbasis transfer learning tetap efektif dalam lingkungan data terbatas, khususnya pada komoditas hortikultura. Pendekatan ini memperkuat bahwa fitur visual seperti warna dan tekstur kulit nanas dapat ditangkap secara optimal oleh jaringan dalam, dibandingkan proses manual yang sering tidak konsisten.

Sementara itu, Wang dan Chai [21] mengusulkan metode ekstraksi ciri berbasis warna menggunakan jalur diagonal untuk mengatasi distribusi warna nanas yang tidak merata. Metode ini menghasilkan akurasi hingga 86% untuk klasifikasi tiga kelas kematangan. Pendekatan berbasis warna ini masih relevan pada kondisi pencahayaan terkontrol dan memberikan efisiensi tinggi karena tidak memerlukan komputasi berat seperti model deep learning. Temuan ini menunjukkan bahwa metode berbasis RGB thresholding tetap kompetitif pada kasus tertentu, terutama ketika pemrosesan real-time menjadi prioritas.

Selain itu, penelitian Vernanda et al. [22] menerapkan metode Support Vector Machine (SVM) sebagai model klasifikasi berdasarkan nilai histogram citra. Dengan memanfaatkan parameter statistik seperti mean, variance, skewness, dan entropy, penelitian tersebut memperoleh akurasi sekitar 65,59%.



Meskipun lebih rendah dibandingkan pendekatan CNN, metode ini tetap memiliki keunggulan pada kompleksitas model yang lebih rendah dan implementasi yang lebih cepat, sehingga cocok digunakan untuk aplikasi sederhana atau perangkat terbatas.

Kemudian, studi lain menunjukkan keberagaman metodologi. Misalnya, pendekatan berbasis fuzzy logic ataupun model berbasis kombinasi beberapa fitur warna juga ditemukan efektif pada konteks tertentu. Hal ini tercermin pada penelitian-penelitian lanjutan dalam referensi [23] dan [24], yang menekankan pentingnya pemilihan fitur relevan serta preprocessing yang tepat untuk meningkatkan performa klasifikasi.

Tabel 2. 5 Akurasi Penelitian Objek Buah Nanas dengan Berbagai Metode

Metode	Tujuan	Kelas	Akurasi	R	S	P	f1-score	No Ref
YOLOv2 berbasis CNN	Klasifikasi	4	99.27%	99%	99%	99%	99%	[20]
deep learning berbasis CNN	Deteksi	4	90.49%	91%	91%	91%	91%	[22]
CNN	Klasifikasi	2	86%	86%	86%	86%	86%	[21]
RGB	Ekstraksi fitur	3	86,05%	90,3	93%	90,7	90%	[23]
SVM	Klasifikasi	3	65.59%	66.25%	80%	65.99%	66.11%	[24]

Tabel 2.5 merangkum secara komprehensif berbagai metode klasifikasi kematangan nanas yang digunakan pada sejumlah penelitian, lengkap dengan tingkat akurasi, jenis fitur yang digunakan, serta jumlah kelas kematangan yang dianalisis. Pada penelitian pertama yang tercantum dalam tabel, Liandaputra dan Zahra [20] menerapkan arsitektur deep learning MobileNetV2 untuk mengidentifikasi empat kelas kematangan nanas. Model ini mencapai akurasi



yang sangat tinggi, yaitu 93%, karena memanfaatkan keunggulan transfer learning untuk mengekstraksi fitur warna dan tekstur kulit nanas secara mendalam. Tingginya akurasi tersebut membuktikan bahwa CNN modern sangat efektif untuk mendeteksi pola visual kompleks, sehingga cocok diterapkan pada citra buah yang bervariasi dalam tekstur dan warna.

Kemudian, penelitian yang dilakukan oleh Wang dan Chai [21] berfokus pada pengukuran proporsi piksel kuning dengan menerapkan enam garis diagonal pada citra buah. Penelitian ini menghasilkan akurasi 86%, yang didapat dari pengukuran langsung perubahan warna kulit nanas pada tiga kelas kematangan: unripe, ripe, dan fully ripe. Pendekatan ini sederhana namun efektif, terlebih pada citra yang memiliki keseragaman pencahayaan. Teknik ekstraksi warna berbasis RGB thresholding ini sesuai bagi aplikasi ringan atau real-time karena tidak memerlukan komputasi intensif seperti CNN.

Sementara itu, penelitian Vernanda et al. [22] memberikan pendekatan berbeda dengan memanfaatkan fitur statistik orde pertama dari histogram RGB, seperti mean, variance, skewness, kurtosis, dan entropy. Penelitian ini hanya mencapai akurasi 65,59%, tetapi hal tersebut sangat dipengaruhi oleh variasi pencahayaan, perbedaan permukaan buah, serta kompleksitas tekstur kulit nanas. Meskipun akurasinya lebih rendah, SVM tetap memiliki kelebihan dari sisi kestabilan klasifikasi dan kompleksitas komputasi yang rendah. Pendekatan ini cocok diterapkan jika sistem ditujukan untuk proses yang cepat dan tidak memerlukan model besar.

Adapun dalam penelitian lain yang disebutkan pada tabel, metode pemrosesan citra seperti segmentasi Otsu, pemisahan objek dengan hresholding,



atau pengambilan fitur struktural telah terbukti meningkatkan kualitas fitur sebelum tahap klasifikasi. Penelitian pada referensi [23] menegaskan bahwa segmentasi yang akurat dapat meminimalkan noise sehingga model klasifikasi menerima fitur yang lebih bersih. Hal ini penting karena kualitas fitur sangat berpengaruh terhadap hasil akhir akurasi model, terutama dalam citra yang diambil di lingkungan tidak terkontrol.

Sementara itu, penelitian pada [24] menunjukkan bahwa fitur statistik seperti entropi dan skewness memiliki hubungan yang kuat dengan perubahan tekstur kulit nanas selama pematangan. Fitur-fitur tersebut efektif untuk mendeskripsikan pola distribusi warna dan ketajaman tekstur pada kulit buah. Oleh karena itu, meskipun tidak menghasilkan akurasi setinggi CNN, metode statistik tetap relevan untuk aplikasi tertentu yang mengutamakan kecepatan, kesederhanaan, dan kemudahan implementasi.

Secara keseluruhan, Tabel 2.5 memperlihatkan bahwa metode CNN memberikan akurasi tertinggi, diikuti oleh pendekatan ekstraksi warna berbasis diagonal, sedangkan metode berbasis histogram dan SVM menghasilkan performa yang paling rendah namun tetap stabil. Dari hasil tersebut dapat disimpulkan bahwa pemilihan metode sangat bergantung pada kebutuhan sistem, seperti ketelitian yang diinginkan, jenis fitur yang tersedia, serta kemampuan komputasi perangkat yang digunakan. Kombinasi antara fitur visual yang tepat dan metode klasifikasi yang sesuai menjadi kunci dalam membangun model klasifikasi tingkat kematangan buah nanas yang efektif.



Tabel 2. 6 Akurasi Penggunaan Model Hybrid CNN-SVM dari Berbagai Penelitian

Objek	Akurasi	Recall	Specifity	Precision	f1-score	No Ref
Lukisan	93.28%	93%	93%	93%	93%	[16]
Tumor	98.92%	98.92%	98.92%	98.92%	98.92%	[17]
Biji kakoa	98.32 %	98.32 %	98.32 %	98.32 %	98.32 %	[18]
Tebu	86.97%	87%	87%	87%	87%	[19]

Dari hasil pada tabel dapat dilihat bahwa seluruh model hybrid CNN–SVM menunjukkan performa tinggi di berbagai objek penelitian. Akurasi tertinggi mencapai 98,92% pada klasifikasi tumor dengan metode ADAM, sedangkan model lain seperti RBF dan GPM juga menunjukkan hasil konsisten di atas 85%. Nilai precision, recall, dan F1-score yang seimbang menandakan stabilitas model dalam mengenali pola citra yang beragam. Ini memperkuat dasar teoritis penggunaan CNN–SVM dalam penelitian klasifikasi kematangan buah nanas. Keberagaman dataset juga memengaruhi hasil klasifikasi tingkat kematangan nanas. Penelitian terdahulu menggunakan jumlah dataset dan jumlah kelas yang berbeda, yang turut berpengaruh terhadap kompleksitas model dan akurasi yang dihasilkan. Rangkuman dataset yang digunakan disajikan pada tabel berikut.

Tabel 2. 7 Dataset Penelitian Objek Buah Nanas dari Berbagai Penelitian

Metode	Jumlah Dataset	Kelas	No Ref	
YOLOv2 berbasis CNN	8.852	4	[20]	
CNN	100	2	[21]	
mobilenetV2+GAP+dense layer	400	4	[22]	
RGB	86	3	[23]	
SVM	299	3	[24]	



Berdasarkan tabel, terlihat bahwa jumlah dataset yang besar seperti pada metode YOLOv2 dengan 8.852 citra menghasilkan akurasi tertinggi, yaitu 99,27% dengan empat kelas kematangan. Sebaliknya, jumlah dataset yang kecil seperti pada metode CNN dengan 100 citra menghasilkan akurasi yang relatif lebih rendah. Oleh karena itu, dalam penelitian ini jumlah dan variasi data menjadi pertimbangan penting untuk memastikan model hybrid CNN–SVM dapat belajar secara optimal terhadap ciri visual dari setiap tingkat kematangan buah nanas.

Berdasarkan hasil kajian penelitian terdahulu, dapat disimpulkan bahwa optimasi pada model deep learning, khususnya Convolutional Neural Network (CNN), berperan penting dalam meningkatkan akurasi klasifikasi citra. Berbagai metode optimasi seperti ADAM, Grid Search, dan Genetic Algorithm (GA) telah terbukti mampu memperbaiki parameter model sehingga performanya meningkat signifikan. Model hybrid CNN–SVM menjadi pendekatan yang banyak digunakan karena menggabungkan keunggulan CNN dalam mengekstraksi fitur dan SVM dalam melakukan klasifikasi non-linear. Berbagai penelitian menunjukkan bahwa model ini menghasilkan akurasi tinggi, bahkan mencapai lebih dari 99% pada objek citra buah, biji kakao, maupun penyakit.

Pada penelitian klasifikasi kematangan buah nanas, metode berbasis CNN mampu memberikan hasil akurasi tinggi hingga 86%, sedangkan SVM masih terbatas pada sekitar 65%. Hal ini menunjukkan bahwa penggabungan kedua metode dapat menjadi solusi untuk meningkatkan kestabilan dan akurasi klasifikasi tingkat kematangan nanas.





Selain itu, jumlah dataset berpengaruh besar terhadap hasil klasifikasi. Dataset yang besar dan beragam, seperti pada penelitian dengan metode YOLOv2, menghasilkan akurasi lebih tinggi dibanding dataset kecil. Oleh karena itu, penelitian ini menekankan pentingnya penggunaan data yang cukup dan representatif agar model hybrid CNN–SVM dapat bekerja secara optimal. Secara keseluruhan, hasil kajian literatur menunjukkan bahwa optimasi model hybrid CNN–SVM merupakan pendekatan yang relevan dan potensial untuk meningkatkan akurasi, stabilitas, serta efisiensi klasifikasi tingkat kematangan buah nanas.

Berdasarkan hasil kajian literatur yang telah disajikan pada Tabel 2.1 hingga Tabel 2.7, terlihat bahwa penelitian terkait klasifikasi kematangan buah nanas masih menghadapi beberapa keterbatasan, terutama dalam hal jumlah kelas yang digunakan, teknik ekstraksi fitur, serta ukuran dataset yang relatif kecil. Sebagian besar penelitian terdahulu hanya menggunakan 2–4 kelas kematangan, sementara model yang digunakan pun beragam, mulai dari metode berbasis warna, teknik statistik, SVM, hingga arsitektur CNN. Meskipun menunjukkan capaian yang cukup baik, metode-metode tersebut belum sepenuhnya mampu menangani variasi tekstur dan warna yang kompleks pada kulit nanas.

Untuk menggambarkan secara jelas posisi penelitian yang akan dilakukan dibandingkan penelitian sebelumnya, maka diperlukan sebuah tabel perbandingan yang menunjukkan perbedaan signifikan dari aspek metode, jumlah kelas kematangan, serta jumlah dataset yang digunakan. Tabel posisi penelitian ini berfungsi untuk mempertegas kontribusi dan kebaruan (novelty) penelitian yang

dikembangkan, yaitu penerapan model hybrid CNN–SVM dengan lima kelas kematangan serta dataset yang jauh lebih besar dibandingkan penelitian terdahulu. Dengan demikian, tabel berikut memberikan gambaran jelas mengenai celah penelitian yang berhasil dijawab melalui penelitian ini.

Tabel 2. 8 Tabel Posisi Penelitian yang dilakukan

Metode	Jumlah Kelas	Dataset	Objek	Akurasi	No ref
SVM	3	299 citra	Nanas	65.59%	[22]
Ekstraksi warna(R GB)	3	86 citra	Nanas	86.05%	[21]
CNN	4	1000 citra	Nanas	93%	[20]
Hybrid CNN-SVM	3	1500 citra	Lukisan	93.28%	[16]
Hybrid CNN-SVM	5	5000	Nanas	-	-

Berdasarkan perbandingan pada tabel 2.6 dapat dilihat bahwa setiap metode dalam penelitian terdahulu memiliki keunggulan sekaligus keterbatasan masing-masing. Metode SVM murni memang sederhana dan cepat, namun akurasi masih rendah karena fitur yang digunakan masih terbatas pada warna dan histogram. Pendekatan ekstraksi warna GB mampu menangkap perubahan warna kulit nanas, tetapi sangat dipengaruhi oleh kondisi pencahayaan dan kualitas gambar. Sementara CNN tunggal memberikan akurasi yang tinggi berkat kemampuannya mengekstraksi fitur yang lebih dalam, namun tetap memiliki keterbatasan dalam proses klasifikasi akhirnya.

Pada saat yang sama, penelitian hybrid CNN-SVM pada objek lain menunjukkan bahwa kombinasi metode ini mampu mengoptimalkan kedua peran, dimana CNN berfungsi sebagai feature extractor yang kuat, sedangkan



SVM memberikan pemisahan kelas yang lebih tegas. Namun penelitian-penelitian tersebut umumnya belum diterapkan pada sebuah nanas dan masih terbatas pada jumlah kelas yang sedikit dan dataset yang kecil

Melihat keseluruhan pola tersebut, keputusan untuk menggunakan Hybrid CNN–SVM dengan 5 kelas kematangan dan 5000 dataset pada penelitian ini adalah langkah yang sangat tepat dan memiliki landasan ilmiah yang kuat. Pendekatan ini secara langsung menjawab kekurangan penelitian sebelumnya, yaitu keterbatasan jumlah kelas, keterbatasan dataset, dan penggunaan metode tunggal yang tidak cukup merepresentasikan kompleksitas tekstur serta warna kulit nanas pada tiap tahap kematangan.

Oleh karena itu, pemilihan metode penelitian ini dapat dinyatakan sangat layak untuk dikembangkan, karena tidak hanya memperluas cakupan penelitian terdahulu, tetapi juga memberikan kontribusi baru dalam bentuk model klasifikasi tingkat kematangan nanas yang lebih rinci, lebih informatif, serta memiliki potensi kinerja yang lebih unggul pada dataset besar dan beragam

