

BAB II

KAJIAN PUSTAKA

2.1 Tinjauan Pustaka

Convolutional Neural Network (CNN) telah terbukti sangat efektif dalam memproses dan menganalisis citra dalam berbagai aplikasi, termasuk klasifikasi biologis seperti identifikasi telur cacing. Dalam konteks ini, *transfer learning* memungkinkan peneliti untuk memanfaatkan pengetahuan yang telah ada dari model yang telah dilatih pada dataset besar, sementara *fine-tuning* memungkinkan penyesuaian model tersebut pada data spesifik yang digunakan dalam penelitian. Penelitian terdahulu telah menyoroti berbagai pendekatan dalam klasifikasi menggunakan teknik pemrosesan citra dan *deep learning* dengan berbagai metode (Tan dkk., 2019). Tabel 2.1 menunjukkan perbandingan penelitian sebagai tinjauan pustaka.

Tabel 2. 1 Perbandingan Penelitian

No	Penulis	Judul	Metode	Hasil
1	Elif Baykal, Hulya Dogan, Mustafa Emre Ercin, Safak Ersoz, Murat Ekinci.	<i>Transfer learning with pre-trained deep Convolutional Neural Networks for serous cell classification.</i>	1. Transfer Learning: Penelitian ini memanfaatkan pendekatan transfer learning, di mana CNN yang telah dilatih sebelumnya digunakan sebagai dasar untuk tugas klasifikasi sel serosa. Model	Metode yang diusulkan mencapai akurasi yang mengesankan sebesar 93,44% saat menggunakan model ResNet. Model ResNet mengungguli model lain yang diuji dalam

No	Penulis	Judul	Metode	Hasil
			yang digunakan meliputi AlexNet, GoogleNet, ResNet, dan DenseNet. 2. Deep Convolutional Neural Networks (CNNs): Penelitian ini menggunakan CNN dalam tugas klasifikasi gambar untuk mengenali sel serosa. CNN yang sudah dilatih sebelumnya, seperti VGG16, ResNet, atau Inception, digunakan untuk mengekstraksi fitur dari gambar sel. 3. Fine-Tuning: Model yang sudah dilatih	penelitian ini, termasuk AlexNet, GoogleNet, dan DenseNet, dalam hal kinerja klasifikasi. Studi ini juga menyoroti pentingnya teknik augmentasi data, seperti rotasi gambar, terjemahan, dan pencerminan (Baykal dkk., 2020).

No	Penulis	Judul	Metode	Hasil
			sebelumnya biasanya disesuaikan (fine-tuned) pada data spesifik sel serosa. 4. Evaluasi Model: Setelah model dilatih dan disesuaikan, kinerja model dievaluasi menggunakan metrik seperti akurasi, sensitivitas, spesifisitas, dan Area Under the Curve (AUC) dari Receiver Operating Characteristic (ROC).	
2	Satish Kumar, Tasleem Arif, Abdullah S. Alotaibi, Majid B. Malik,	<i>Advances Towards Automatic Detection and Classification of Parasites</i>	1. Deep Convolutional Neural Networks (CNNs): Penelitian ini menggunakan	Hasil eksperimen melaporkan akurasi yang mengesankan 98% untuk

No	Penulis	Judul	Metode	Hasil
	Jatinder Manhas.	<i>Microscopic Images Using Deep Convolutional Neural Network: Methods, Models and Research Directions.</i>	CNN untuk mendeteksi dan mengklasifikasikan gambar mikroskopis parasit. 2. Eksperimen dan Validasi: Penelitian melibatkan eksperimen ekstensif dengan menggunakan dataset gambar mikroskopis parasit. 3. Arsitektur Model yang Beragam: AlexNet, VGGNet, ResNet, dan Inception, yang dioptimalkan untuk performa pada dataset gambar parasit.	model yang diusulkan setelah memproses kumpulan data yang berisi 1300 gambar, yang selanjutnya disempurnakan menjadi 100.000 sel berlabel. Di antara berbagai model yang dievaluasi, AlexNet dan Fast R-CNN mencapai akurasi tertinggi dalam mendeteksi dan mengklasifikasi parasit (Kumar dkk., 2023).
3	Zongwei Zhou, Jae Y. Shin,	<i>Active, continual fine tuning of</i>	1. Fine-Tuning: Metode fine-tuning aktif yang	Hasil penelitian menyoroti kemajuan yang

No	Penulis	Judul	Metode	Hasil
	Suryakanth R. Gurudu, Michael B. Gotway, Jianming Liang.	<i>Convolutional Neural Networks for reducing annotation efforts.</i>	berkelanjutan untuk CNN, model diperbarui secara terus-menerus dengan data baru yang dipilih secara aktif berdasarkan kinerja model saat ini. 2. Pendekatan Pemilihan Data Berbasis Kinerja: Pemilihan data berbasis kinerja model, di mana hanya data yang paling sulit atau tidak pasti dipilih untuk anotasi lebih lanjut. 3. Evaluasi Eksperimental: Menguji pada beberapa dataset medis untuk menilai efektivitas metode ini dalam mengurangi	signifikan dalam mengurangi biaya anotasi dalam analisis citra medis melalui integrasi inovatif fine-tuning dan transfer learning, dengan implikasi yang menjanjikan untuk masa depan sistem CAD. Hasil menunjukkan bahwa metode baru mengungguli metode seleksi acak canggih, mencapai pengurangan biaya anotasi hingga 81,5% untuk klasifikasi kerangka kolonoskopi, 86,3% untuk deteksi polip,

No	Penulis	Judul	Metode	Hasil
			usaha anotasi tanpa mengorbankan akurasi model CNN.	dan 80,3% untuk deteksi emboli paru (Z. Zhou dkk., 2021).
4	Saminathan, Pranesh	<i>Adaptive Multi-Layer Ensemble Learning (AMEL) for Robust and Accurate Predictive Modelling in Big Data Analytics.</i>	Metode Adaptive Multi-Layer Ensemble Learning (AMEL) menggabungkan beberapa model prediktif pada berbagai lapisan ensemble dengan mekanisme pembobotan adaptif berbasis kinerja untuk meningkatkan akurasi, stabilitas, dan robustness prediksi pada skenario big data yang bersifat kompleks dan heterogen.	Pendekatan ensemble adaptif berlapis secara signifikan meningkatkan akurasi, stabilitas, dan robustness prediksi dibandingkan model tunggal dan ensemble konvensional pada dataset big data yang kompleks (P. Saminathan, 2024).
5	Sterniczuk, B. Charytanowicz, M.	<i>An Ensemble Transfer Learning Model for</i>	Menggunakan ensemble beberapa CNN pra-latih berbasis transfer	Menunjukkan bahwa model ensemble berbasis transfer

No	Penulis	Judul	Metode	Hasil
		<i>Brain Tumors Classification using Convolutional Neural Networks.</i>	learning, di mana fitur dan prediksi dari masing-masing model digabungkan untuk meningkatkan akurasi klasifikasi tumor otak pada citra medis.	learning mampu meningkatkan akurasi klasifikasi tumor otak secara signifikan, serta memberikan performa yang lebih stabil dan andal dibandingkan penggunaan satu model CNN tunggal pada citra MRI otak (BP. Sterniczuk dkk., 2024).
6	S Sunny, S Pinky, S Jalal, M Kayser, M Wadud, N Mansoor	<i>Soft Voting Ensemble-Based Approach for Diagnosing Diabetes Mellitus.</i>	Mengombinasikan beberapa algoritma pembelajaran mesin dengan mekanisme soft voting berbasis probabilitas untuk menghasilkan diagnosis diabetes yang lebih akurat dan stabil dibandingkan model tunggal.	Menunjukkan bahwa pendekatan soft voting ensemble meningkatkan akurasi dan keandalan diagnosis diabetes mellitus, serta mengurangi tingkat

No	Penulis	Judul	Metode	Hasil
				kesalahan klasifikasi dibandingkan penggunaan satu algoritma pembelajaran mesin saja (S. Sunny dkk., 2024).

2.1.1 Telur Cacing

Secara ilmiah, telur cacing adalah bentuk reproduksi dari cacing yang hidup di dalam inang. Telur ini biasanya memiliki dinding yang keras dan dapat bertahan dalam lingkungan yang tidak bersahabat, seperti tanah atau air, sampai menemukan inang yang sesuai untuk berkembang. Telur cacing parasit dapat bervariasi dalam ukuran, bentuk, dan struktur, tergantung pada spesiesnya. Misalnya, telur cacing pita, cacing tambang, dan cacing gelang memiliki morfologi yang berbeda. Telur ini berperan penting dalam siklus hidup cacing, karena mereka melepaskan larva ketika dicerna oleh inang atau saat berada dalam kondisi yang tepat di lingkungan (Anindita dkk., 2022).

Infeksi cacing pada manusia biasanya terjadi melalui makanan, air, atau tanah yang terkontaminasi oleh telur atau larva cacing, atau melalui kontak langsung dengan hewan yang terinfeksi. Pemeriksaan yang umumnya dilakukan dalam mendiagnosis infeksi *nematoda* usus berupa mendeteksi telur cacing atau larva pada feses manusia. Pemeriksaan rutin feses dilakukan secara makroskopis dan mikroskopis. Pemeriksaan makroskopis dilakukan untuk menilai warna, konsistensi, jumlah, bentuk, bau serta ada-tidaknya mukus dan parasite (Rahmadhini & Mutiara, 2020). Sedangkan pemeriksaan mikroskopis bertujuan untuk memeriksa *leukosit*, jenis *protozoa*, dan telur cacing (Dompeipen dkk., 2021).

Dalam penelitian Palasuwan (2022), telur-telur cacing dibedakan berdasarkan beberapa ciri penting, seperti bentuk, ukuran, dan tekstur. Bentuk telur cacing sangat bervariasi antar spesies, di mana beberapa berbentuk oval, bulat, atau lonjong. Ukuran juga menjadi faktor pembeda, karena spesies telur cacing parasit memiliki dimensi yang spesifik. Tekstur permukaan telur cacing, apakah halus atau kasar, juga digunakan sebagai ciri penting untuk pengklasifikasian. Namun, dalam konteks penelitian ini, deteksi yang paling diandalkan adalah bentuk dan ukuran karena kualitas gambar yang dihasilkan oleh mikroskop USB berbiaya rendah tidak memungkinkan penggunaan fitur warna dan tekstur secara optimal. Ciri-ciri ini, terutama bentuk dan ukuran, sangat penting dalam membantu model *deep learning* seperti ResNet50 dan *AlexNet* dalam melakukan klasifikasi telur secara otomatis pada gambar mikroskopik berkualitas rendah (Palasuwan dkk., 2022). Penelitian ini, menggunakan 11 kelas telur cacing yang terdiri dari:

1. *Ascaris lumbricoides*


Ascaris lumbricoides (cacing gelang) termasuk ke dalam jenis *nematoda* dan tergolong dalam kelompok *Soil Transmitted Helminths (STH)*. *STH* adalah cacing yang dalam siklus hidupnya memerlukan tanah yang sesuai untuk berkembang menjadi bentuk infeksi (Wihardji, 2022). Cacing ini memiliki ciri ukuran yang cukup besar, cacing betina bisa mencapai panjang 20-35 centimeter dengan bentuk memiliki ujung ekor yang lurus, sedangkan cacing jantan lebih kecil sekitar 15-31 centimeter dengan ujung ekor yang melengkung. Tekstur telur *Ascaris lumbricoides* umumnya kasar dan bergranula tidak beraturan akibat adanya lapisan albuminoid (*mammillated layer*) yang menyelimuti dinding telur, meskipun pada kondisi tertentu dapat tampak lebih halus bila lapisan tersebut terlepas. Tubuhnya berbentuk silindris dan memanjang, biasanya berwarna krem atau putih kekuningan. Telurnya berbentuk oval dengan dinding yang tebal dan lapisan luar yang bergelombang (Else et al., 2020). Bentuk dari cacing *Ascaris lumbricoides* dewasa dan telurnya dapat dilihat pada gambar 2.1.



Gambar 2. 1 *Ascaris lumbricoides* dewasa (a), dan telurnya (b).

2. *Capillaria philippinensis*

Cacing ini termasuk dalam jenis *nematoda* yang menyebabkan penyakit *capillariasis* terutama pada saluran usus halus, yang mana penyebarannya berkaitan dengan konsumsi ikan yang belum dimasak secara benar (mentah). Cacing ini pertama kali ditemukan di Filipina, kemudian dilaporkan adanya kasus sporadis di daerah lain. Lebih dari 2.000 kasus *capillariasis* usus telah dilaporkan di Filipina dan Thailand, dengan kasus sporadis dilaporkan di Korea, Jepang, Taiwan, India, Iran, Mesir, Italia, Uni Emirat Arab, Spanyol, dan Inggris (Khalifa dkk., 2020). Cacing ini memiliki ciri-ciri dengan ukuran kecil, cacing jantan biasanya memiliki panjang 1,5 hingga 3,9 milimeter, sedangkan cacing betina 2,3 hingga 5,3 milimeter. Bentuknya seperti benang (*filiform*) dengan ujung anterior yang tumpul dan posterior sedikit melengkung. Telur cacingnya berbentuk oval, dindingnya tebal, dan kutubnya rata. Panjangnya sekitar 36 – 45 mikrometer, dan lebarnya 20 – 25 mikrometer. Tekstur telur cacing *Capillaria philippinensis* umumnya halus hingga sedikit berstri dengan dinding tipis, memiliki permukaan relatif licin serta ciri khas operkulum datar di kedua kutub, sehingga tampak lebih homogen dibandingkan telur cacing berlapis kasar, permukaan telur memiliki alur atau striations yang halus (Khalifa dkk., 2020). Gambar 2.2 adalah bentuk dari cacing *Capillaria philippinensis* dewasa dan telurnya.



Gambar 2. 2 *Capillaria philippinensis* dewasa (a), dan telurnya (b).

3. *Enterobius vermicularis*


Nematoda Enterobius vermicularis atau yang dikenal sebagai “cacing kremi” adalah jenis cacing yang bersifat parasit dan menyerang atau menjangkiti usus besar manusia. Cacing ini memiliki karakteristik fisik yang sekilas terlihat seperti benang dan berwarna putih atau putih kekuningan, sehingga terlihat jelas di feses atau di area anus. Cacing kremi memiliki rata-rata panjang tubuh 5–13 milimeter. Salah satu faktor yang menyebabkan terjadinya penularan *Enterobius vermicularis* antara lain adalah suhu udara, dimana infeksi di daerah dingin lebih tinggi daripada di daerah panas. Hal ini bisa disebabkan umumnya pada orang di daerah dingin yang jarang mandi dan mengganti pakaian dalam, menyebabkan rasa gatal yang sering kali menjadi gejala utama infeksi. Gejala utamanya adalah pruritus ani atau gatal di area anus, terutama di malam hari. Infeksi yang parah dapat menyebabkan gangguan tidur, iritasi kulit, atau bahkan infeksi sekunder karena garukan. Tekstur telur cacing ini umumnya halus, tipis, dan transparan, dengan permukaan licin tanpa ornamen kasar serta bentuk asimetris (planokonveks) yang membedakannya dari telur cacing usus lainnya (Zahara dkk., 2022). Gambar 2.3 adalah bentuk dari cacing *Enterobius vermicularis* dewasa dan telurnya (Zahara dkk., 2022). Gambar 2.3 adalah bentuk dari cacing *Enterobius vermicularis* dewasa dan telurnya.



Gambar 2. 3 *Enterobius vermicularis* dewasa (a), dan telurnya (b).

4. *Fasciolopsis Buski*

Trematoda jenis *Fasciolopsis buski* merupakan penyebab dari penyakit *Fasciolopsis*. Cacing ini hidup dan berkembang di dalam *duodenum* dan *jejunum* manusia sebagai hospes definitifnya atau hewan sebagai hospes perantaranya. *Fasciolopsis buski* umum ditemukan di Asia, seperti Bangladesh, Cina, Taiwan, Vietnam, Kamboja, Laos, Thailand, Malaysia, Indonesia, Burma dan India (Ompusunggu, 2020). Cacing ini memiliki bentuk seperti daun, dengan panjang 20-75 milimeter dan lebar 8-20 milimeter, merupakan trematoda terbesar yang menginfeksi usus manusia. Infeksi pada manusia terjadi melalui konsumsi air atau makanan yang terkontaminasi larva cacing (metaserkaria), biasanya ditemukan pada tanaman air seperti eceng gondok atau kacang air. Setelah tertelan, larva berubah menjadi cacing dewasa dalam usus manusia. Tekstur telur cacing ini umumnya halus dan homogen dengan dinding telur tipis hingga sedang, permukaan licin tanpa struktur bergranula, serta dilengkapi operkulum yang jelas pada salah satu ujungnya (Saikia dkk., 2022). Gambar 2.4 adalah bentuk dari cacing *Fasciolopsis buski* dewasa dan telurnya (Saikia dkk., 2022). Gambar 2.4 adalah bentuk dari cacing *Fasciolopsis buski* dewasa dan telurnya.



Gambar 2. 4 *Fasciolopsis buski* dewasa (a), dan telurnya (b).

5. *Hookworm*

Hookworm atau yang lebih dikenal sebagai cacing tambang, diketahui telah menjadi parasit bagi manusia sejak zaman Mesir Kuno jauh sebelum *Ascaris Lumbricoides* (Cacing Gelang) dan *Trichuris trichiura* (cacing cambuk) diperkenalkan, cacing ini termasuk dalam kelompok *Soil Transmitted Helminths* (Hendratno, 2020). Ciri cacing *Hookworm* dewasa memiliki panjang 7-13 milimeter, dengan bentuk tubuh silindris dan mulut yang dilengkapi dengan gigi atau struktur pengait yang digunakan untuk menempel di dinding usus manusia. Cacing ini memiliki siklus hidup yang dimulai ketika larva menembus kulit manusia, biasanya melalui telapak kaki yang tidak terlindungi. Larva kemudian bergerak melalui pembuluh darah, menuju paru-paru, dan akhirnya ditelan ke usus, kemudian berkembang menjadi cacing dewasa. Tekstur telur *hookworm* umumnya halus dan transparan dengan dinding telur tipis, permukaan licin tanpa ornamen, serta isi embrio yang tampak jelas pada pemeriksaan mikroskopis (Heukelbach & Feldmeier, 2008). Gambar 2.5 adalah bentuk dari larva *hookworm rhabditiform* dan telurnya.



Gambar 2. 5 Larva *hookworm rhabditiform* (a), dan telurnya (b).

6. *Hymenolepis nana*


Cacing ini merupakan cacing pita terkecil yang dapat hidup dalam usus manusia, walaupun hanya sebagai hospes aksidental. Nama lain cacing ini adalah cacing pita kerdil. Infeksi cacing ini tersebar di seluruh dunia dengan angka kejadian tertinggi di daerah tropis dan sub-tropis. Kasus infeksi cacing ini banyak terjadi pada anak-anak dan merupakan satu-satunya cacing pita yang penularannya langsung dari manusia ke manusia (Setya, 2020). Ciri cacing dewasa berukuran kecil hanya 15-40 milimeter panjangnya, memiliki bentuk pipih seperti pita dengan scolex (kepala) yang dilengkapi kait dan empat pengisap. Cacing ini memiliki siklus hidup unik yang dapat menyelesaikan seluruh siklusnya dalam tubuh inang tanpa memerlukan inang perantara. Telur yang dikeluarkan melalui feses bisa langsung menginfeksi individu yang sama (autoinfeksi) atau orang lain. Larva berkembang di usus kecil dan tumbuh menjadi cacing dewasa. Tekstur telur cacing ini umumnya halus dengan dinding telur tipis hingga sedang, memiliki membran dalam berstri halus serta filamen polar khas, sehingga permukaannya tampak relatif homogen namun berciri struktural internal yang jelas (Archer dkk., 2024). Gambar 2.6 adalah bentuk dari cacing *Hymenolepis nana* dewasa dan telurnya.



Gambar 2. 6 *Hymenolepis nana* dewasa (a), dan telurnya (b).

7. *Hymenolepis diminuta*


Cacing ini disebut dengan cacing pita yang terutama menginfeksi hewan pengerat tetapi juga bisa menginfeksi manusia, meskipun infeksi pada manusia lebih jarang dibandingkan dengan *Hymenolepis nana*. Manusia dapat terinfeksi secara kebetulan oleh cacing ini. Yang membedakan dari *Hymenolepis nana* adalah stadium telurnya tidak memiliki filamen-filamen, dan bentuk telurnya cenderung bulat (tidak oval) (Setya, 2020). Ukuran dan bentuk cacing dewasa lebih besar dibandingkan *Hymenolepis nana*, dengan panjang 20-60 centimeter. Cacing ini memiliki tubuh pipih dan segmen-segmen yang disebut proglotid. Scolex (kepala) cacing ini tidak memiliki kait, hanya empat penghisap untuk menempel pada dinding usus. Tekstur telur cacing ini umumnya halus dan homogen dengan dinding telur relatif tebal, permukaan licin tanpa filamen polar, sehingga tampak lebih sederhana dibandingkan telur *Hymenolepis nana* (Kapczuk dkk., 2020). Gambar 2.7 adalah perbandingan cacing *H. nana* dengan *H. diminuta* dewasa, dan telur cacing *H. diminuta*.



Gambar 2. 7 Perbandingan *H. nana* (a, c) dengan *H. diminuta* (b, d) dewasa, dan telur *H. diminuta* (e).

8. *Opisthorchis viverrini*

Cacing yang termasuk dalam filum trematoda ini disebut juga sebagai cacing daun hati kucing, sebab pertama kali ditemukan pada hati kucing *Felis viverrini*. Nama lain cacing ini adalah *Distoma viverrini*. Cacing ini ditemukan di Asia bagian Selatan, khususnya di Thailand. Selain di Thailand, cacing ini juga terdapat di Laos, Kamboja, Vietnam, Malaysia dan India. Cacing ini berparasit pada saluran empedu yang mengakibatkan lesi-lesi dan pada beberapa kasus terkadang menyebabkan kematian (Ompusunggu, 2020). Ciri-ciri cacing ini memiliki panjang 5-10 milimeter dan lebar 1-2 milimeter, memiliki tubuh pipih dan berbentuk seperti daun yang khas dari trematoda, berwarna abu-abu atau cokelat kekuningan. Cacing ini membutuhkan dua inang perantara: siput air dan ikan air tawar. Manusia dan mamalia lain terinfeksi saat mengonsumsi ikan yang terinfeksi mentah atau setengah matang. Setelah tertelan, larva cacing berkembang menjadi cacing dewasa di saluran empedu manusia, dimana mereka dapat hidup selama beberapa dekade. Tekstur telur *Opisthorchis viverrini* umumnya halus dan homogen dengan dinding telur tipis, memiliki operkulum kecil yang jelas serta tonjolan (knob) di ujung posterior, sehingga tampak licin tanpa ornamen kasar (Pengput & Schwartz, 2020). Gambar 2.8 adalah bentuk dari cacing *Opisthorchis viverrini* dewasa dan telurnya.




Gambar 2. 8 *Opisthorchis viverrini* dewasa (a), dan telurnya (b).

9. *Paragonimus spp*

Trematoda yang berdiam di paru-paru semuanya masuk dalam kategori *Paragonimus spp*. Awal mulanya, cacing ini ditemukan pada seekor berang-berang raksasa (*Pteronura brasiliensis*) di Brazil pada tahun 1828 dan 22 tahun kemudian disebut sebagai *Distomum rude*. Selanjutnya beberapa spesies lainnya dari genus ini mulai dilaporkan dari berbagai penjuru dunia, identifikasi spesies yang memadai baru dilakukan belakangan ini. Sebagai contoh, *Paragonimus pulmonalis* sudah dipisahkan dari *P. westermani* pada tahun 1978, persis 100 tahun setelah penemuan *P. pulmonalis* tersebut pada tahun 1878 (Ompusunggu, 2020). Ciri-ciri cacing ini berbentuk seperti kacang merah dengan panjang 7-12 milimeter dan lebar 4-6 milimeter. Tubuhnya pipih dan berwarna kemerahan atau kecokelatan. Cacing ini memiliki struktural *oral sucker* (alat penghisap mulut) yang digunakan untuk menempel pada jaringan iang. Siklus hidupnya melibatkan dua inang perantara, yaitu air tawar dan krustasea (seperti kepiting atau udang air tawar). Infeksi pada manusia terjadi setelah mengonsumsi krustasea yang terkontaminasi larva cacing yang belum matang. Cacing ini bermigrasi melalui dinding usus dan masuk ke paru-paru yang akan membentuk kista. Tekstur telur *Paragonimus spp*. umumnya halus dengan dinding telur tebal, permukaan relatif licin, serta dilengkapi operkulum jelas dengan penebalan di bahu

(shoulders) yang menjadi ciri khasnya (Sun dkk., 2022). Gambar 2.9 adalah bentuk dari cacing *Paragonimus westermani* dewasa dan telurnya.



Gambar 2. 9 *Paragonimus westermani* dewasa (a), dan telurnya (b).

10. *Taenia spp.*

Taenia spp adalah cacing pita yang dapat menyebabkan infeksi pada manusia, dengan dua spesies yang paling umum adalah *Taenia solium* (cacing pita babi) dan *Taenia saginata* (cacing pita sapi). *Taenia spp* adalah kelompok cacing pita yang menyebabkan penyakit cacing pita pada manusia dan hewan. Ciri-ciri cacing ini memiliki ukuran yang sangat panjang mencapai 2-10 meter. Tubuhnya terdiri dari scolex (kepala) yang memiliki pengisap dan kait untuk *Taenia saginata*, serta rantai proglotid (segmen tubuh). Proglotid ini mengandung organ reproduksi dan dapat melepaskan telur (Konyaev dkk., 2017). Tahapan hidupnya mencakup dua inang, yaitu inang antara (biasanya hewan seperti babi, sapi, atau domba) dan inang akhir (manusia atau hewan karnivora seperti anjing dan kucing). Manusia dapat terinfeksi *Taenia spp* melalui makanan atau air yang terkontaminasi dengan telur cacing pita, sementara hewan inang antara terinfeksi melalui konsumsi makanan yang terkontaminasi dengan telur cacing pita dari feses inang akhir. Ketika seseorang atau hewan inang antara menelan telur *Taenia spp* telur tersebut menetas dan larva cacing pita menembus dinding usus dan menyebar ke organ tubuh yang lain. Tekstur telur *Taenia spp*. umumnya kasar dan berstri radial akibat dinding telur tebal (embryophore), dengan permukaan tidak licin yang


membedakannya dari telur cacing pita lainnya. (Setya, 2020). Gambar 2.10 adalah bentuk dari cacing *Taenia saginata* dewasa dan telurnya.



Gambar 2. 10 *Taenia saginata* dewasa (a), dan telurnya (b).

11. *Trichuris trichiura*

Cacing yang tergolong dalam filum *nematoda* ini dikenal juga sebagai *whipworm* atau cacing cambuk. Cacing ini hidup di usus besar terutama *sekum*, tetapi pada infeksi berat dapat hidup di area yang lebih luas, mulai dari *ileum* bagian bawah sampai ke *rektum*. (Hendratno, 2020). Ciri telurnya berbentuk oval dengan ukuran panjang sekitar 50 mikrometer dan lebar 23 mikrometer, memiliki dua lapisan dinding yaitu lapisan luar berwarna kekuningan dan lapisan dalam yang transparan. Pada kedua ujung telur terdapat tonjolan yang disebut *polar plug*, telur ini berisi embrio. Sedangkan ciri cacing dewasa berbentuk seperti cambuk dimana 3/5 dari panjang tubuhnya (sebelah anterior) tipis seperti benang, sedangkan 2/5 bagian (sebelah posterior) terlihat lebih tebal. Cacing jantan panjangnya sekitar 4 centimeter, dengan ujung posterior melingkar atau melengkung ke arah ventral dengan sebuah *spicula* di ujungnya. Cacing betina panjangnya sekitar 5 centimeter, dengan ujung posterior lurus dan tumpul membulat. Tekstur telur *Trichuris trichiura* umumnya halus dan homogen dengan dinding telur tebal, permukaan relatif licin, serta sumbat kutub (*polar plugs*) di kedua ujung yang menjadi ciri morfologi khas (Rivero dkk., 2020). Gambar 2.11 adalah bentuk dari cacing *Trichuris trichiura* dewasa dan telurnya.



Gambar 2. 11 *Trichuris trichiura* dewasa (a), dan telurnya (b).

2.1.2 Klasifikasi

Klasifikasi merupakan cara pengelompokan benda berdasarkan ciri – ciri yang dimiliki oleh objek klasifikasi. Dalam prosesnya, klasifikasi dapat dilakukan dengan banyak cara baik secara manual ataupun dengan bantuan teknologi. Klasifikasi yang dilakukan secara manual adalah klasifikasi yang dilakukan oleh manusia tanpa adanya bantuan dari algoritma cerdas komputer. Sedangkan klasifikasi yang dilakukan dengan bantuan teknologi, memiliki beberapa algoritma, diantaranya *Naïve Bayes*, *Support Vector Machine*, *Decision Tree*, *Fuzzy* dan *Jaringan Saraf Tiruan* (Jain dkk., 2019).


Metode klasifikasi yang digunakan dalam penelitian ini melibatkan penerapan CNN untuk klasifikasi telur cacing berdasarkan teknik pemrosesan gambar. Tiga arsitektur CNN digunakan dalam penelitian ini: *EfficientNetB0*, *MobileNetv3*, dan *ResNet50*, yang dikenal karena efektivitasnya dalam tugas klasifikasi gambar. *Transfer learning* digunakan dengan memanfaatkan model pra-terlatih pada kumpulan data gambar skala besar untuk menginisialisasi arsitektur CNN untuk tugas klasifikasi telur cacing. *Fine tuning* kemudian dilakukan pada lapisan terakhir model CNN untuk menyesuaikannya secara khusus dengan karakteristik data telur cacing, mengoptimalkan kinerjanya untuk tugas klasifikasi ini. Pengujian eksperimental dilakukan dengan menggunakan kumpulan data sekunder telur cacing yang dikumpulkan dari IEEE *Dataport* (<https://ieee-dataport.org/competitions/parasitic-egg-detection-and-classification-microscopic-images>) oleh Duangdao (Nantakomol) Palasuwan. Dataset terdiri dari 11 jenis telur cacing, yang mana

setiap kategori berjumlah 1.000 gambar dengan total keseluruhan 11.000 gambar telur cacing (Palasuwan dkk., 2022).

2.1.3 Pengolahan Citra (*Image Processing*)

Citra atau *image* adalah suatu cahaya pada bidang dua dimensi. Ditinjau dari sudut pandang matematis, citra merupakan fungsi kontinu dari intensitas cahaya pada bidang dua dimensi. Sumber cahaya menerangi objek, objek memantulkan kembali sebagian dari berkas cahaya tersebut. Pantulan cahaya ini ditangkap oleh alat-alat optik, misalnya mata pada manusia, kamera, scanner, dan sebagainya, sehingga bayangan objek yang disebut citra tersebut terekam. Citra juga dapat dianggap sebagai objek dua dimensi yang dihasilkan dari citra analog yang kontinu dan kemudian dapat diubah menjadi citra diskrit melalui proses *sampling*. *Sampling* adalah pemilihan titik-titik yang dianggap mewakili citra digital yang diberikan. *Sampling* dapat juga didefinisikan sebagai pengurangan *signal* kontinu menjadi *signal* diskrit (Wahyuni & Sulaeman, 2022). Citra digital dapat diolah dengan komputer karena berbentuk data numerik (Paliwang dkk., 2020).

Sebuah citra adalah kumpulan piksel-piksel yang disusun dalam bidang dua dimensi. Indeks baris dan kolom (x,y) dalam sebuah piksel dinyatakan dengan bilangan bulat. Piksel (0,0) terletak pada sudut kiri atas pada citra, indeks x bergerak ke kanan dan indeks y bergerak ke bawah. Sistem koordinat pada citra ini berkebalikan dengan sistem koordinat grafik matematika atau kartesian. Gambar 2.12 menunjukkan perbedaan titik asal antara dua jenis sistem koordinat tersebut.



Gambar 2. 12 Koordinat dalam Citra Digital

Pada umumnya citra digital berbentuk empat persegi panjang dengan lebar dan panjang tertentu. Ukuran citra biasanya diukur dalam jumlah titik atau piksel, dimana setiap piksel mempunyai koordinat menurut letaknya di dalam citra digital. Koordinat ini biasanya dinyatakan dalam bilangan integer yang besarnya dari 0 sampai dengan 1 tergantung dari sistem yang digunakan. Setiap piksel berisi nilai yang mewakili informasi apa yang ada dalam piksel. Citra (*image*) juga dapat didefinisikan sebagai fungsi dua dimensi $f(x, y)$ di mana x dan y adalah koordinat spasial dan amplitudo f pada setiap pasang (x, y) disebut intensitas (*gray level*) citra pada titik tersebut. Jika x dan y berhingga (*finite*) dan diskrit (tidak kontinu) maka disebut citra digital. Citra digital terdiri dari sejumlah elemen berhingga yang masing-masing mempunyai lokasi dan nilai, elemen-elemen x dan y disebut elemen citra atau pels atau piksel (Iriyanto & Zaini, 2014).


Pengolahan citra digital (*digital image processing*) adalah sebuah disiplin ilmu yang mempelajari tentang teknik- teknik mengolah citra. Citra yang dimaksud disini adalah gambar diam (foto) maupun gambar bergerak (video). Sedangkan digital disini mempunyai maksud bahwa pengolahan citra dilakukan secara digital menggunakan komputer (MZ dkk., 2022). Secara matematis, citra merupakan fungsi kontinyu (*continuous*) dengan intensitas cahaya pada bidang dua dimensi. Agar dapat diolah dengan komputer digital, maka suatu citra harus dipresentasikan secara numerik dengan nilai diskrit. Representasi dari fungsi kontinyu menjadi nilai-nilai diskrit disebut digitalisasi citra. Tujuan dari pengolahan citra ini adalah memperbaiki kualitas suatu citra sehingga dapat diinterpretasi dengan mudah oleh manusia atau sebuah mesin (komputer).

2.1.4 Convolutional Neural Network

CNN adalah pengembangan dari *Multilayer Perceptron* (MLP) yang didesain untuk mengolah data dua dimensi (Dompeipen dkk., 2021). CNN termasuk dalam jenis *deep neural network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra (Andriani & Kom, 2020).

CNN digunakan untuk mengklasifikasikan data yang berlabel dengan menggunakan metode *supervised learning*, dimana terdapat data yang dilatih dan

terdapat variabel yang ditargetkan sehingga tujuan dari metode ini adalah mengelompokkan suatu data ke data yang sudah ada. Pada CNN terdapat beberapa lapisan yang berperan untuk melakukan *filtering* ketika proses pelatihan, lapisan-lapisan tersebut adalah *Covolutional Layer*, *Pooling Layer* dan *Fully Connected Layer*. Gambar 2.13 menunjukkan arsitektur CNN yang terdiri atas dua bagian utama yaitu *Feature dan Classification*.



Gambar 2. 13 Arsitektur CNN


Convolutional layer merupakan lapisan terpenting dalam CNN. Seperti namanya, lapisan konvolusional ini terdiri dari blok bangunan dasar yang disebut konvolusi. Konvolusi dilakukan ke sebagian kecil gambar, buat sampel nilai piksel di area itu, lalu ubah menjadi satu piksel. Menerapkan ke setiap area piksel pada gambar untuk menghasilkan gambar baru yang disebut *feature maps*. *Pooling layer* terdiri dari dua jenis tipe yaitu *Max Pooling* dan *Average Pooling*. *Max pooling* mengambil nilai yang terbesar, sedangkan *average pooling* mengambil nilai rata-rata. *Pooling Layer* merupakan lapisan yang menggunakan fungsi dengan *feature map* sebagai masukan dan mengolahnya dengan berbagai macam operasi statistik berdasarkan nilai piksel terdekat. Lapisan *pooling* pada model CNN biasanya disisipkan secara teratur setelah beberapa lapisan konvolusi. Lapisan *pooling* yang dimasukkan di antara lapisan konvolusi secara berturut-turut dalam arsitektur model CNN dapat secara progresif mengurangi ukuran volume *output* pada *feature map*, sehingga jumlah parameter dan perhitungan di jaringan berkurang, serta untuk

mengendalikan *overfitting*. *Fully Connected Layer* adalah lapisan di mana semua *neuron* yang diaktifkan dari lapisan sebelumnya semuanya terhubung ke *neuron* di lapisan berikutnya, seperti halnya *neural network* biasa. Pada dasarnya *layer* ini biasanya digunakan pada MLP yang bertujuan untuk mengubah dimensi data agar data dapat diklasifikasikan secara *linier*. Perbedaan antara *fully connected layer* dan *convolution layer* biasa adalah *neuron* pada *convolution layer* hanya terhubung ke daerah *input* tertentu, sedangkan *fully connected layer* memiliki *neuron* yang terhubung sepenuhnya.

2.1.5 Arsitektur EfficientNet-B0

EfficientNet merupakan serangkaian model yang diturunkan dari jaringan dasar, dilakukan dengan pengaturan penskalaannya. Kelebihan dari *EfficientNet* yaitu memberikan akurasi yang tinggi, dan mampu memperbaiki efektivitas model, dengan melakukan pengurangan parameter dan *FLOPS* (*Floating Point Operations Per Second*). *EfficientNet* mengadopsi metode skala penggabungan pada semua dimensi jaringan (*network*) diantaranya yaitu lebar (*width*) mengacu pada jumlah *channel* pada lapisan manapun, kedalaman (*depth*) mengacu pada jumlah lapisan di *CNN*, dan resolusi (*resolution*) mengacu pada ukuran resolusi gambar yang digunakan (Basyir, 2021). Gambar 2.14 menampilkan struktur dari *EfficientNet-B0*.


SEKOLAH PASCASARJANA

Gambar 2. 14 Struktur *EfficientNet-B0*

2.1.6 Arsitektur MobileNet-V3

MobileNet adalah suatu jenis arsitektur model jaringan saraf tiruan (*neural network*) yang dikembangkan oleh *Google* untuk digunakan dalam tugas-tugas pengolahan gambar dan pengenalan objek pada perangkat bergerak atau perangkat dengan sumber daya terbatas. Arsitektur MobileNetV3 memiliki keunggulan dalam efisiensi komputasi dan kecepatan proses karena dirancang khusus untuk perangkat dengan sumber daya terbatas seperti *mobile* dan *embedded system*. Model ini menggunakan kombinasi teknik seperti *depthwise separable convolution*, *squeeze-and-excitation (SE) module*, serta optimasi berbasis *Neural Architecture Search (NAS)* sehingga mampu menghasilkan performa yang baik dengan ukuran model yang lebih kecil. Selain itu, MobileNetV3 juga efektif untuk *transfer learning*, memiliki latensi rendah, dan tetap mampu mengekstraksi fitur penting pada citra, sehingga cocok digunakan untuk klasifikasi citra medis yang membutuhkan keseimbangan antara akurasi dan efisiensi. (Howard dkk., 2019) didalam *paper*

yang berjudul “*Searching for MobileNetV3*” memaparkan bahwa *MobileNetV3* dikategorikan ke dalam dua model yaitu *MobileNetV3-Large* dan *MobileNetV3-Small* yang masing-masingnya ditargetkan untuk penggunaan sumberdaya besar dan rendah. Arsitektur ini disusun dengan kombinasi antara *depthwise separable convolutions* pada *MobileNetV1*, *linear bottleneck* dan struktur *inverted residual* pada *MobileNetV2* dan *lightweight attention modules* yang berbasis *squeeze and excitation* yang diterapkan pada *MnasNet* untuk memperbaiki tingkat akurasi pada titik tertentu (Howard dkk., 2019). Gambar 2.15 adalah struktur dari *MobileNetV3Large*.



Gambar 2. 15 Struktur *MobileNetV3Large*


2.1.7 Arsitektur ResNet-50

ResNet adalah singkatan dari *Residual Network*, model ini pertama kali diperkenalkan oleh Kaiming He, Xiangyu Zhang, Shaoqing Ren, dan Jian Sun pada tahun 2015 di dalam makalah penelitian *computer vision* yang berjudul “*Deep Residual Learning for Image Recognition*”. Model ini menjadi sangat populer setelah memperoleh posisi teratas pada kompetisi ILSVRC (*ImageNet Large Scale Visual Recognition Challenge*) pada tahun 2015 (Tsang, 2018). *ResNet* memiliki

berbagai varian, *ResNet50* adalah salah satu varian *ResNet* yang menggunakan 50 *neural network layers*. Arsitektur *ResNet-50* memiliki keunggulan utama dalam kemampuannya mengatasi masalah *vanishing gradient* melalui penggunaan *residual connections* atau *skip connections*, sehingga memungkinkan pelatihan jaringan yang lebih dalam tanpa mengalami degradasi performa. Dengan kedalaman 50 layer, *ResNet-50* mampu mengekstraksi fitur yang lebih kompleks dan representatif dari citra, termasuk detail penting pada citra medis seperti morfologi telur cacing. Selain itu, arsitektur ini memiliki kemampuan generalisasi yang baik, stabil dalam proses pelatihan, serta sangat efektif digunakan dalam *transfer learning*, sehingga sering digunakan sebagai backbone dalam berbagai tugas klasifikasi citra dengan tingkat akurasi yang tinggi.

ResNet-50 merupakan salah satu arsitektur dari CNN yang memperkenalkan sebuah konsep baru yaitu *shortcut connections*. Munculnya konsep *shortcut connections* yang ada pada arsitektur *ResNet-50* memiliki keterkaitan dengan *vanishing gradient problem* yang terjadi ketika usaha memperdalam struktur suatu *network* dilakukan. Bagaimanapun memperdalam suatu *network* dengan tujuan meningkatkan performansinya tidak bisa dilakukan hanya dengan cara menumpuk *layer*. Semakin dalam suatu *network* dapat memunculkan *vanishing gradient problem* yang bisa membuat *gradient* menjadi sangat kecil yang berakibat pada menurunnya performansi atau akurasi (Nashrullah dkk., 2020). Gambar 2.16 adalah struktur dari *ResNet-50*.

SEKOLAH PASCASARJANA

Gambar 2. 16 Struktur *ResNet-50*

2.1.8 Ensemble Learning

Ensemble Models dalam *machine learning* adalah pendekatan yang menggabungkan beberapa model prediktif untuk menghasilkan kinerja yang lebih baik dibandingkan model tunggal. Ide utama dari ensemble adalah bahwa setiap model memiliki kelebihan dan keterbatasan masing-masing, sehingga penggabungan beberapa model dapat mengurangi kesalahan prediksi dan meningkatkan kemampuan generalisasi terhadap data baru. Keberhasilan ensemble sangat bergantung pada diversitas model, yaitu perbedaan perilaku atau pola kesalahan antar model yang digunakan. Jika beberapa model membuat kesalahan yang berbeda pada data yang sama, maka kombinasi prediksi mereka dapat saling melengkapi sehingga menghasilkan keputusan yang lebih akurat.

Beberapa teknik utama dalam *ensemble learning*, yaitu:

1. *Bagging (Bootstrap Aggregating)*

Metode ini melatih beberapa model menggunakan subset data yang berbeda yang dihasilkan melalui proses bootstrap sampling. Hasil prediksi kemudian digabungkan, biasanya menggunakan metode voting atau rata-rata.

2. *Boosting*

Pendekatan ini membangun model secara berurutan, di mana setiap model baru berfokus pada sampel data yang sebelumnya salah diklasifikasikan oleh model sebelumnya. Dengan demikian, model secara bertahap meningkatkan kemampuan prediksi pada data yang sulit.

3. *Voting* atau *Averaging*

Metode ini menggabungkan keluaran beberapa model dengan mekanisme pemungutan suara (*hard voting*) atau rata-rata probabilitas (*soft voting*) untuk menentukan prediksi akhir.

Selain itu, bab ini menjelaskan bahwa ensemble models sering digunakan pada berbagai aplikasi seperti klasifikasi, regresi, dan analisis data skala besar karena kemampuannya meningkatkan akurasi, stabilitas, dan *robustness* model terhadap variasi data (Obregon, J., 2022).

2.1.9 *Adaptive Multi-Backbone / Confidence-Entropy*

Adaptive Multi-Backbone / Confidence-Entropy merupakan pendekatan dalam sistem klasifikasi berbasis *ensemble deep learning* yang memanfaatkan beberapa arsitektur backbone CNN secara bersamaan dan kemudian memilih atau menggabungkan prediksi berdasarkan tingkat kepercayaan (*confidence*) dan ketidakpastian (*entropy*) dari setiap model.

2.1.10 Konsep *Adaptive Multi-Backbone*

Pendekatan ini menggunakan lebih dari satu model CNN sebagai *feature extractor* atau *classifier backbone*. Setiap *backbone*, misalnya *EfficientNet*, *ResNet*, atau *MobileNet*, memiliki karakteristik berbeda dalam mengekstraksi fitur citra. Dalam sistem ini, beberapa backbone dilatih pada dataset yang sama, lalu hasil prediksi masing-masing model digabungkan menggunakan mekanisme adaptif. Tujuannya

adalah meningkatkan akurasi, stabilitas model, dan kemampuan generalisasi dibandingkan penggunaan satu model saja.

2.1.11 Konsep *Confidence–Entropy*

Metode ini digunakan untuk mengukur tingkat kepastian prediksi model.

1. *Confidence* menunjukkan probabilitas tertinggi dari kelas yang diprediksi oleh model. Semakin tinggi nilai *confidence*, semakin yakin model terhadap prediksinya.
2. *Entropy* mengukur ketidakpastian distribusi probabilitas dari output model. *Entropy* rendah berarti model sangat yakin terhadap satu kelas, sedangkan *entropy* tinggi menunjukkan prediksi masih ambigu.

Dalam pendekatan ini, keputusan akhir dapat dibuat dengan cara:

1. Memilih prediksi dari model dengan *confidence* tertinggi, atau
2. Memprioritaskan model dengan *entropy* terendah karena menunjukkan prediksi yang lebih stabil.

Tujuan Penggabungan *Adaptive Multi-Backbone* dan *Confidence–Entropy* ini adalah untuk:

1. Meningkatkan akurasi klasifikasi.
2. Mengurangi kesalahan prediksi model Tunggal.

Meningkatkan keandalan sistem klasifikasi citra, terutama pada dataset yang kompleks atau memiliki kemiripan visual antar kelas (Khatri dkk., 2025).

2.1.12 Evaluasi Statistik untuk *Ensemble*

Evaluasi statistik pada metode *ensemble learning* bertujuan untuk menilai apakah peningkatan performa yang dihasilkan dari penggabungan beberapa model benar-benar signifikan dibandingkan model tunggal. Dalam bidang *Machine Learning*, *ensemble* menggabungkan beberapa model klasifikasi untuk memperoleh prediksi yang lebih akurat, stabil, dan memiliki kemampuan generalisasi yang lebih baik. Oleh karena itu, selain menggunakan metrik performa seperti *accuracy*, *precision*, *recall*, dan *F1-score*, diperlukan evaluasi statistik untuk memastikan bahwa perbedaan kinerja antar model tidak terjadi secara kebetulan.

Salah satu metode evaluasi statistik yang umum digunakan adalah McNemar Test, yaitu uji non-parametrik yang membandingkan hasil prediksi dua model pada dataset yang sama untuk mengetahui apakah perbedaannya signifikan secara statistik. Selain itu, *confidence interval* juga digunakan untuk mengukur tingkat keandalan hasil evaluasi dan memperkirakan rentang performa model pada populasi data yang lebih luas. Dengan menerapkan evaluasi statistik tersebut, peneliti dapat memastikan bahwa model *ensemble* yang dikembangkan benar-benar memberikan peningkatan performa yang valid dan dapat dipertanggungjawabkan secara ilmiah (Harine, R., 2021).

2.1.13 Metode Diagnostik Telur Cacing sebagai *Gold Standard*

Diagnosis infeksi cacing pada manusia umumnya dilakukan melalui pemeriksaan laboratorium terhadap sampel feses untuk mendeteksi keberadaan telur cacing. Metode yang paling banyak digunakan dalam praktik diagnostik adalah pemeriksaan mikroskopis karena mampu mengidentifikasi telur cacing secara langsung berdasarkan karakteristik morfologi yang khas. Karakteristik tersebut meliputi bentuk telur, ukuran, warna, ketebalan dinding telur, serta struktur internal yang dapat diamati menggunakan mikroskop. Oleh karena itu, pemeriksaan mikroskopis telah lama digunakan sebagai metode standar dalam bidang *Parasitology* untuk menentukan jenis infeksi cacing.

Beberapa teknik pemeriksaan mikroskopis yang umum digunakan antara lain metode Kato-Katz *technique*, metode *direct smear*, dan metode konsentrasi seperti *formalin-ether concentration technique*. Metode Kato-Katz merupakan teknik kuantitatif yang banyak digunakan untuk mendeteksi telur cacing pada sampel feses, khususnya untuk infeksi *soil-transmitted helminths* seperti *Ascaris lumbricoides*, *Trichuris trichiura*, dan *Ancylostoma duodenale*. Teknik ini memungkinkan pengamatan telur cacing dengan jelas serta dapat digunakan untuk menghitung intensitas infeksi berdasarkan jumlah telur per gram feses. Metode *direct smear* merupakan teknik pemeriksaan sederhana yang dilakukan dengan menempatkan sampel feses pada kaca objek, kemudian diamati secara langsung di bawah mikroskop. Metode ini sering digunakan sebagai pemeriksaan awal karena

prosesnya relatif cepat dan mudah dilakukan. Selain itu, terdapat metode konsentrasi seperti *formalin-ether concentration technique* yang bertujuan untuk meningkatkan sensitivitas deteksi dengan memisahkan telur cacing dari material lain dalam sampel feses sehingga telur lebih mudah diamati (Keller dkk., 2020).

Dalam praktik diagnostik laboratorium, metode-metode tersebut sering digunakan oleh analis laboratorium atau ahli parasitologi untuk mengidentifikasi telur cacing berdasarkan karakteristik morfologinya. Metode pemeriksaan mikroskopis ini juga direkomendasikan oleh *World Health Organization* sebagai prosedur standar dalam surveilans dan diagnosis infeksi *soil-transmitted helminths*. Karena mampu memberikan identifikasi langsung terhadap morfologi telur cacing serta telah digunakan secara luas dalam praktik klinis dan penelitian epidemiologi, metode ini dianggap sebagai *gold standard* dalam penentuan jenis telur cacing. Dalam penelitian berbasis pengolahan citra dan pembelajaran mesin, hasil identifikasi telur cacing yang diperoleh melalui pemeriksaan mikroskopis oleh ahli parasitologi digunakan sebagai ground truth untuk proses pelabelan dataset. Label tersebut kemudian menjadi acuan dalam proses pelatihan, validasi, dan evaluasi model klasifikasi citra sehingga performa model dapat dibandingkan dengan hasil diagnosis yang telah diakui sebagai standar referensi (De Vivero dkk., 2026). Tabel 2.2 merupakan perbandingan dari metode diagnostik telur cacing.

Tabel 2. 2 Perbandingan Metode Diagnostik Telur Cacing

No	Metode Diagnostik	Prinsip Pemeriksaan	Kelebihan	Kekurangan	Kegunaan Utama
1	<i>Kato-Katz technique.</i>	Sampel feses ditempatkan pada template khusus kemudian diamati di bawah mikroskop untuk mendeteksi dan menghitung jumlah telur cacing.	Dapat menghitung intensitas infeksi (<i>egg per gram</i>), metode standar surveilans epidemiologi.	Sensitivitas lebih rendah pada infeksi ringan dan beberapa jenis telur yang mudah rusak.	Diagnosis dan <i>surveilans infeksi Soil Transmitted Helminths.</i>

No	Metode Diagnostik	Prinsip Pemeriksaan	Kelebihan	Kekurangan	Kegunaan Utama
2	<i>Direct Smear</i> (Pemeriksaan langsung).	Sampel feses diletakkan langsung pada kaca objek kemudian diamati menggunakan mikroskop.	Prosedur sederhana, cepat, dan biaya rendah.	Sensitivitas relatif rendah karena tidak ada proses konsentrasi sampel.	Pemeriksaan awal infeksi cacing di laboratorium.
3	<i>Formalin–Ether Concentration Technique.</i>	Sampel feses diproses dengan larutan formalin dan eter untuk memisahkan telur cacing dari kotoran lain.	Sensitivitas lebih tinggi karena telur terkonsentrasi.	Proses preparasi lebih kompleks dan membutuhkan bahan kimia tambahan.	Deteksi telur cacing pada infeksi dengan jumlah telur rendah.
4	<i>Flotation Technique.</i>	Sampel dicampur dengan larutan dengan densitas tinggi sehingga telur cacing mengapung dan mudah diamati.	Sensitivitas cukup baik untuk beberapa jenis telur cacing.	Tidak semua jenis telur dapat mengapung dalam larutan flotasi.	Digunakan dalam beberapa pemeriksaan parasitologi.
5	<i>PCR-based Detection.</i>	Mengidentifikasi DNA parasit dalam sampel.	Sensitivitas sangat tinggi dan spesifik.	Biaya mahal dan membutuhkan fasilitas molekuler.	Penelitian molekuler dan konfirmasi spesies.

2.2 Keaslian Penelitian

Penelitian ini mengusulkan pendekatan klasifikasi citra telur cacing berbasis deep learning dengan mengombinasikan beberapa teknik pembelajaran modern untuk meningkatkan kinerja klasifikasi pada dataset citra mikroskopis. Keaslian penelitian ini terletak pada integrasi beberapa metode yang digunakan secara terpadu dalam satu kerangka sistem klasifikasi. Pendekatan yang digunakan dalam penelitian ini meliputi:

1. *Transfer Learning* dan *Fine-Tuning* pada *Multi - Backbone CNN*

Penelitian ini memanfaatkan tiga arsitektur Convolutional Neural Network (CNN) yang telah dilatih sebelumnya, yaitu MobileNetV3, EfficientNetB0,

dan ResNet50, sebagai backbone model. Model pra-latih tersebut kemudian disesuaikan dengan dataset telur cacing melalui proses fine-tuning sehingga mampu mengekstraksi fitur spesifik dari citra mikroskopis parasit.

2. *Ensemble Learning Berbasis Multi-Backbone Model*

Penelitian ini mengombinasikan beberapa model CNN yang berbeda melalui pendekatan ensemble learning. Setiap model menghasilkan probabilitas prediksi terhadap kelas telur cacing, kemudian hasil tersebut digabungkan untuk memperoleh keputusan klasifikasi yang lebih stabil dan akurat dibandingkan model tunggal.

3. *Soft Voting untuk Penggabungan Probabilitas Model*

Metode soft voting digunakan untuk menggabungkan probabilitas prediksi dari setiap model backbone. Dengan pendekatan ini, keputusan klasifikasi tidak hanya didasarkan pada satu model, tetapi mempertimbangkan kontribusi seluruh model yang terlibat.

4. *Adaptive Ensemble Berbasis Confidence–Entropy Weighting*

Penelitian ini mengembangkan pendekatan adaptive ensemble dengan memanfaatkan nilai confidence dan entropy dari probabilitas prediksi model. Metode ini memberikan bobot adaptif pada setiap model berdasarkan tingkat keyakinan dan ketidakpastian prediksi sehingga kombinasi model dapat menghasilkan keputusan klasifikasi yang lebih optimal.

Selain itu, penelitian ini menggunakan dataset citra telur cacing yang diperoleh dari IEEE Dataport, yang terdiri dari berbagai kelas telur cacing pada citra mikroskopis. Penggunaan dataset dari sumber terpercaya serta penerapan metode multi-backbone ensemble dengan mekanisme adaptive weighting menjadi kontribusi utama dalam pengembangan sistem klasifikasi otomatis pada penelitian ini. Dengan mengintegrasikan transfer learning dan *adaptive multi-backbone ensemble*, penelitian ini diharapkan dapat meningkatkan performa klasifikasi citra telur cacing secara lebih akurat dan robust dibandingkan pendekatan model tunggal.

2.3 Landasan Teori

Penelitian Kumar (2023) mengenai deteksi otomatis dan klasifikasi gambar mikroskopis parasit adalah: Metode pembelajaran mendalam, khususnya CNN, menunjukkan hasil yang menjanjikan dalam hal efisiensi dan akurasi dalam klasifikasi dan deteksi parasit. Penggunaan model CNN untuk pengenalan visual telah diuraikan sebagai konsep dasar dalam pembelajaran mendalam untuk deteksi dan klasifikasi parasit. Metode pembelajaran mesin tradisional, seperti *Artificial Neural Networks* (ANN), juga telah digunakan untuk mengidentifikasi parasit tertentu dengan akurasi tinggi. Teknik pembelajaran mesin, seperti jaringan saraf probabilistik, telah berhasil digunakan untuk mengenali dan mengklasifikasikan kista parasit usus dari gambar mikroskopis. Hasil eksperimen menunjukkan bahwa model berbasis ANN dapat mengidentifikasi gambar kista *Cryptosporidium* dan *Giardia* dengan benar dengan akurasi tinggi, mulai dari 91,8% hingga 99,6% (Kumar dkk., 2023).

Hasil penelitian Lim (2022) tentang segmentasi ovum parasit usus manusia menggunakan pembelajaran mesin dan Teknik *deep learning*. Studi ini membandingkan kinerja segmentasi pembelajaran mesin menggunakan teknik *Fuzzy C-mean* (FCM) dan segmentasi pembelajaran mendalam menggunakan teknik CNN. Akurasi yang diperoleh untuk setiap spesies cacing menggunakan kedua teknik berkisar antara 97% hingga 100%. Namun, ketika menganalisis *Intersection over Union* (IoU), CNN berdasarkan teknik *ResNet* berkinerja lebih baik daripada FCM untuk *Ascaris Lumbricoides Ova* (ALO), *Enterobius Vermicularis Ova* (EVO), dan *Trichuris Trichiura Ova* (TTO) dengan nilai masing-masing 75,80%, 55,48%, dan 77,06%. Studi ini menyimpulkan bahwa segmentasi melalui pembelajaran mendalam CNN lebih cocok untuk segmentasi sel telur parasit usus manusia (Lim dkk., 2022).

Penelitian Lee (2022) menjelaskan platform analisis telur cacing dikembangkan sebagai platform identifikasi dan kuantifikasi telur cacing mikroskopis yang mudah digunakan untuk membantu teknisi medis selama pemeriksaan infeksi parasit. *HEAP* mengintegrasikan arsitektur pembelajaran mendalam, seperti deteksi objek dan metode segmentasi seperti SSD, *U-net*, dan *Faster R-CNN*, untuk memberikan

sudut pandang yang lebih cepat dan lebih komprehensif untuk identifikasi dan kuantifikasi telur cacing. Hasil yang dianalisis oleh AI di HEAP dapat direproduksi, menjadikannya alat yang andal untuk analisis telur cacing. HEAP dapat digunakan di komputer pribadi dengan biaya konstruksi rendah dan juga dapat digunakan dalam cluster dengan varian jenis sistem operasi, dengan atau tanpa akselerator GPU. Dengan pengumpulan terus menerus gambar telur cacing dan sampel yang divalidasi manusia, tingkat prediksi dan jenis parasit yang tercakup di HEAP dapat meningkat dan menjadi komprehensif (Lee dkk., 2022).

Jimenez (2020) meneliti studi yang berfokus pada pengembangan dan peningkatan sistem HEAD untuk identifikasi dan kuantifikasi telur cacing dalam sampel lingkungan. Teknik konvensional untuk mengevaluasi telur cacing bergantung pada beberapa langkah, seperti sedimentasi, filtrasi, sentrifugasi, dan flotasi, yang dapat memakan waktu dan padat karya. Sistem HEAD menggunakan algoritma pemrosesan gambar untuk mengotomatiskan identifikasi dan kuantifikasi telur cacing, memberikan alternatif yang lebih cepat dan lebih efisien untuk metode tradisional. Sistem mengalami perbaikan, termasuk proses verifikasi tekstur untuk mengurangi hasil positif palsu dan penetapan ambang batas optimal untuk setiap spesies telur cacing. Sistem yang ditingkatkan mencapai nilai sensitivitas dan spesifisitas yang tinggi, menjadikannya alat yang berguna untuk mengidentifikasi dan mengukur berbagai spesies telur cacing dalam sampel lingkungan yang menantang. Sistem ini memiliki potensi untuk digunakan di fasilitas pemantauan lingkungan dan laboratorium di seluruh dunia, berkontribusi pada deteksi dan pengendalian helminthiasis, masalah kesehatan masyarakat utama (Jiménez, B dkk., 2020).

Penelitian Jimenez (2016) mengembangkan sistem identifikasi tujuh spesies telur cacing pada air limbah dengan spesifisitas 99% dan sensitivitas 80–90%. Sistem ini mampu mengenali variasi morfologi serta tahap perkembangan telur dalam waktu kurang dari satu menit per gambar. Keunggulannya terletak pada efisiensi waktu dan biaya, serta mengurangi ketergantungan pada tenaga ahli yang sangat terlatih. Penelitian ini juga menyebutkan potensi implementasi perangkat lunak di masa depan untuk memasukkan identifikasi parasit lain seperti *protozoa*. Sistem ini dikembangkan secara bertahap menggunakan Matlab dan menggabungkan

berbagai alat pemrosesan gambar dan algoritma pengenalan pola (Jiménez, B dkk., 2016).

Hasil penelitian AlDahoul (2023) tentang pengenalan telur parasit. Model *COATnet* yang diusulkan mencapai kinerja pengenalan tinggi dengan akurasi rata-rata 93% dan skor F1 rata-rata 93% ketika disetel dengan gambar mikroskopis telur parasit. Penelitian membandingkan model yang berbeda, termasuk *DenseNet121*, *EfficientNet-B4*, transformator penglihatan, dan *CoatNet0*, untuk pengenalan telur parasit. Menyetel 40 lapisan terakhir *EfficientNet-B4* CNN menghasilkan akurasi rata-rata tertinggi, ingatan, presisi, dan skor F1. *DenseNet121* CNN, setelah menyetel 20 lapisan terakhir, menunjukkan hasil yang tinggi dalam hal akurasi rata-rata (86), ingatan rata-rata (86), presisi rata-rata (88), dan skor F1 rata-rata (86). Itu mampu mengekstrak fitur informatif yang cocok untuk pengenalan telur parasit. Penelitian ini juga menyoroti potensi penambahan CoatNet sebagai tulang punggung dalam detektor objek untuk mendeteksi dan mengklasifikasikan beberapa telur dengan kategori berbeda dalam satu gambar mikroskopis (AlDahoul dkk., 2023).

Penelitian mengenai klasifikasi partikel campuran berdasarkan pemrosesan pencitraan dengan *Convolutional Neural Network* (CNN) oleh Tian (2021), membahas atribut dalam konteks mengacu pada fitur yang diekstraksi dari gambar partikel campuran, yang digunakan untuk klasifikasi. Metode melibatkan penggalan fitur partikel dari gambar biner dan menggabungkannya dengan desain fitur yang sesuai dengan jenis partikel dan pengklasifikasi seperti jaringan saraf *Back Propagation* (BP) dan *Support Vector Machine* (SVM). Dalam metode berbasis CNN yang diusulkan, fitur partikel diekstraksi menggunakan jaringan saraf *convolutional* dan lokalisasi partikel diperoleh dengan menggunakan jaringan proposal wilayah atau *Region Proposal Network* (RPN). Akurasi dan tingkat penarikan dari metode klasifikasi digunakan sebagai atribut untuk mengevaluasi kinerja teknik yang berbeda. Oleh karena itu, atribut dalam makalah penelitian didefinisikan dengan tepat dan digunakan untuk membandingkan efektivitas metode yang berbeda untuk klasifikasi partikel campuran (Tian dkk., 2021).

Penelitian yang menggunakan kumpulan data daun kacang tunggak yang dikumpulkan dari peternakan penelitian dan menerapkan tiga jaringan saraf konvolusi, termasuk *DenseNet121*, untuk tujuan klasifikasi. Hasil eksperimen menunjukkan bahwa model *DenseNet121* mencapai akurasi tertinggi dalam mendeteksi daun kacang tunggak, dengan akurasi 86,12% untuk dataset pelatihan dan 88,89% untuk dataset pengujian. Studi ini juga membandingkan kinerja arsitektur CNN lainnya, seperti *Inceptionv3* dan *VGG16*, untuk klasifikasi daun kacang tunggak. Tingkat akurasi dan kehilangan entropi model disajikan, dan hasilnya dianalisis untuk mengevaluasi keakuratan model yang disajikan. Studi ini menunjukkan potensi teknik pembelajaran mendalam, khususnya jaringan saraf *convolutional* dalam, untuk mengidentifikasi dan mengklasifikasikan daun kacang tunggak secara akurat, yang dapat bermanfaat bagi peneliti, petani, dan organisasi pertanian (Choudhary dkk., 2023).

Pada penelitian de Paula (2023), bertujuan untuk meningkatkan kinerja sistem *Brain-Computer Interfaces (BCI)* berdasarkan sinyal *Electroencephalogram (EEG)* dengan menggunakan metode *Deep Learning*, khususnya *Convolutional Neural Networks*. Data yang digunakan dalam penelitian ini adalah sinyal *EEG* yang diperoleh dari sistem *Brain-Computer Interfaces (BCI)* berdasarkan sinyal *Electroencephalogram (EEG)*. Hasilnya menunjukkan kinerja yang menguntungkan untuk metode yang diusulkan, menunjukkan potensi sistem *BCI* yang kuat menggunakan data lintas subjek dan interval waktu akuisisi yang singkat. Empat arsitektur secara konsisten mencapai akurasi validasi lebih dari 90%: *Resnet50*, 101, *Densenet161*, dan 201. Metode Plot Rekurensi berkontribusi paling besar pada akurasi yang lebih tinggi, dengan akurasi 94%. Pengklasifikasi berkinerja terbaik adalah *DenseNet161* dengan akurasi 97% dan *ResNet50* dengan akurasi 96%, keduanya menggunakan gambar *Recurrence Plot* (de Paula dkk., 2023).

Penelitian Ma (2023) adalah untuk mengembangkan model klasifikasi biji jagung (*CornNet*) berdasarkan jaringan saraf *convolutional* ringan khusus dan strategi pelatihan yang ditingkatkan. Penelitian ini menghasilkan Model *CornNet* yang mencapai akurasi tinggi, dengan tingkat akurasi 98,56% dan skor F1 98,93%. Ukuran model *CornNet* adalah 0,42MB, biaya komputasi diukur dalam *Floating*

Point (FLOP) adalah 0,07G. Metode yang digunakan berupa Evaluasi kinerja model *CornNet* dalam hal akurasi, skor F1, ukuran model, dan *FLOP*, membandingkannya dengan model lain seperti *MobileNet*, *ShuffleNet*, *VGG16*, *ResNet50*, dan *AlexNet*. Perbandingan metode augmentasi data yang berbeda dan evaluasi berdampak terhadap akurasi, kehilangan, dan waktu pelatihan. Data untuk melatih model klasifikasi biji jagung (*CornNet*) diperoleh dari lingkungan akuisisi gambar yang dibangun untuk mensimulasikan lini produksi, sehingga memberikan fitur yang konsisten dalam skenario terstruktur, mirip dengan pengaturan jalur produksi penyortiran biji jagung di pabrik pengolahan benih. Gambar dikumpulkan dengan lokasi kamera tetap dan kondisi pencahayaan yang seimbang, sehingga mengurangi kebutuhan akan sejumlah besar pengumpulan data dalam skenario yang berbeda untuk generalisasi (Ma dkk., 2023).

2.4 Hipotesis Penelitian

Hipotesis penelitian yang terukur difokuskan pada peningkatan kinerja sistem melalui metode *Adaptive Multi-Backbone Ensemble*. Hipotesis ini diukur dengan membandingkan performa model yang diusulkan terhadap model tunggal dan metode ensemble konvensional menggunakan metrik standar serta uji statistik. Berikut adalah rincian hipotesis yang terukur beserta metrik evaluasinya:

2.4.1 Hipotesis Kinerja Model (Terukur)

Penelitian ini didasarkan pada hipotesis bahwa:

- a. Peningkatan Akurasi: Metode *Adaptive Multi-Backbone Ensemble* berbasis *confidence* dan *entropy* dapat menghasilkan akurasi klasifikasi yang lebih tinggi dibandingkan model tunggal (*EfficientNetB0*, *MobileNetV3Large*, *ResNet50*) maupun metode *soft voting* konvensional.
- b. Stabilitas dan *Robustness*: Pendekatan ensemble adaptif mampu mengurangi kesalahan prediksi pada kasus *fine-grained classification* (sampel dengan ambiguitas visual tinggi) dengan cara menyesuaikan bobot model secara dinamis.

- c. Signifikansi Statistik: Peningkatan performa yang dihasilkan oleh metode *adaptive ensemble* benar-benar signifikan secara statistik dan tidak terjadi secara kebetulan.

2.4.2 Metrik Evaluasi yang Digunakan

Untuk membuktikan hipotesis tersebut secara terukur, penelitian menggunakan metrik berikut:

- a. Akurasi (Accuracy): Mengukur persentase total prediksi benar. Sistem yang diusulkan mencapai akurasi 97,18%.
- b. Presisi (Precision): Mengukur proporsi prediksi positif yang benar.
- c. Recall (Sensitivity): Mengukur sejauh mana model dapat mengidentifikasi seluruh *instance* positif.
- d. F1-Score: Mengukur keseimbangan antara presisi dan recall.

2.4.3 Pengujian Statistik untuk Validasi Hipotesis

Hipotesis divalidasi lebih lanjut melalui dua metode statistik utama:

- a. Uji McNemar: Digunakan sebagai uji non-parametrik untuk membandingkan hasil prediksi dua model pada dataset yang sama guna menentukan apakah perbedaan kinerjanya signifikan secara statistik.
- b. Interval Kepercayaan (*Confidence Interval*) 95%: Digunakan untuk mengukur tingkat keandalan hasil evaluasi dan memperkirakan rentang performa model pada populasi data yang lebih luas.

SEKOLAH PASCASARJANA