

BAB II

TINJAUAN PUSTAKA

2.1 Justifikasi Solusi

Pada bagian ini, penulis meninjau berbagai penelitian terdahulu yang menjadi dasar ilmiah dalam pemilihan solusi untuk menjawab permasalahan yang telah diuraikan pada Bab I. Peninjauan dilakukan untuk membangun justifikasi terhadap setiap komponen solusi yang digunakan dalam penelitian, mulai dari kebutuhan melakukan analisis otomatis pada citra mikroskopis, kebutuhan mengekstraksi karakter morfologi yang bersifat diskriminatif, kebutuhan memanfaatkan pembelajaran pada dataset yang terbatas, hingga kebutuhan memperoleh model yang memiliki keseimbangan antara performa klasifikasi dan efisiensi komputasi. Dengan demikian, setiap metode yang digunakan pada penelitian ini dipilih berdasarkan kesesuaiannya dengan karakteristik permasalahan serta didukung oleh bukti dari penelitian-penelitian sebelumnya.

2.1.1 Deep Learning Models for Automatic Identification of Plant-Parasitic Nematodes

Penelitian yang dilakukan oleh Shabrina, Lika, dan Indarti [7] menjadi salah satu penelitian yang menunjukkan bahwa identifikasi nematoda dapat dilakukan secara otomatis menggunakan citra mikroskopis. Penelitian tersebut mengembangkan sistem identifikasi nematoda parasit tumbuhan berbasis *Deep Learning* dengan memanfaatkan 957 citra mikroskopis yang terdiri atas sebelas genus nematoda parasit tumbuhan yang umum ditemukan di Indonesia. Beberapa arsitektur *Deep Learning*, yaitu ResNet101V2, CoAtNet-0, EfficientNetV2B0, dan EfficientNetV2M dibandingkan untuk mengevaluasi performa klasifikasi genus nematoda. Hasil pengujian menunjukkan bahwa model EfficientNetV2B0 dan EfficientNetV2M mampu mencapai akurasi hingga 97,94%, sehingga menunjukkan bahwa pendekatan berbasis citra mikroskopis memiliki potensi yang

tinggi untuk mendukung proses identifikasi nematoda secara otomatis [7].

Acuan yang dapat diambil dari penelitian ini adalah:

- Penelitian tersebut membuktikan bahwa citra mikroskopis mengandung informasi visual yang cukup untuk dipelajari oleh model *Deep Learning*, sehingga pendekatan berbasis citra layak digunakan sebagai dasar pengembangan sistem bantu identifikasi spesies *Pratylenchus*.
- Keterbatasan penelitian pada klasifikasi tingkat genus menjadi landasan bagi penelitian ini untuk mengembangkan sistem klasifikasi hingga tingkat spesies, khususnya pada *Pratylenchus bolivianus* dan *Pratylenchus pseudocoffeae* yang memiliki kemiripan morfologi tinggi.
- Belum adanya evaluasi terhadap efisiensi waktu identifikasi memperkuat kebutuhan penelitian ini untuk tidak hanya mengevaluasi performa klasifikasi, tetapi juga mengevaluasi waktu inferensi sebagai representasi kemampuan sistem dalam membantu meningkatkan efisiensi proses identifikasi morfologi.

2.1.2 A Survey on Transfer Learning

Meskipun penelitian Shabrina et al. [7] menunjukkan bahwa Deep Learning mampu mengidentifikasi nematoda berdasarkan citra mikroskopis, keberhasilan model *Deep Learning* umumnya dipengaruhi oleh jumlah data pelatihan yang tersedia. Model dengan jumlah parameter yang besar memerlukan dataset dalam jumlah besar agar mampu mempelajari representasi fitur secara optimal. Sementara itu, penelitian ini menggunakan dataset yang terdiri atas 994 citra mikroskopis dari dua spesies *Pratylenchus*, sehingga jumlah data yang tersedia relatif terbatas apabila digunakan untuk melatih model dari kondisi awal (*training from scratch*).

Pan dan Yang [10] menjelaskan bahwa *Transfer Learning* merupakan pendekatan yang memanfaatkan pengetahuan yang telah dipelajari model dari suatu domain sumber untuk membantu menyelesaikan permasalahan pada domain target yang memiliki jumlah data lebih terbatas. Dengan memanfaatkan bobot awal (*pre-trained weights*) yang diperoleh dari proses pelatihan pada dataset berskala besar, model dapat menghasilkan performa yang lebih baik, mempercepat proses konvergensi, serta mengurangi kebutuhan terhadap data pelatihan dibandingkan membangun model dari awal [10]. Pendekatan ini telah banyak diterapkan pada berbagai permasalahan klasifikasi citra dan terbukti mampu meningkatkan kemampuan generalisasi model pada kondisi dataset yang terbatas [6].

Berdasarkan karakteristik dataset yang digunakan, pendekatan *Transfer Learning* dinilai lebih sesuai dibandingkan melatih model dari awal karena memungkinkan model memanfaatkan representasi fitur yang telah dipelajari sebelumnya untuk mengenali karakter morfologi *Pratylenchus*.

Acuan yang dapat diambil dari penelitian ini adalah:

- *Transfer Learning* merupakan pendekatan yang sesuai untuk pengembangan model *Deep Learning* pada dataset dengan jumlah data pelatihan yang relatif terbatas.
- Pemanfaatan bobot awal (*pre-trained weights*) memungkinkan model menghasilkan proses pelatihan yang lebih efisien dan kemampuan generalisasi yang lebih baik dibandingkan pelatihan dari awal (*training from scratch*).
- Berdasarkan karakteristik dataset penelitian ini, pendekatan *Transfer Learning* dipilih sebagai dasar pengembangan model klasifikasi spesies *Pratylenchus*.

2.1.3 *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks dan Densely Connected Convolutional Networks*

Setelah pendekatan *Transfer Learning* dipilih, langkah berikutnya adalah menentukan arsitektur *Deep Learning* yang sesuai dengan karakteristik permasalahan penelitian. Pemilihan arsitektur menjadi penting karena penelitian ini tidak hanya bertujuan memperoleh performa klasifikasi yang tinggi, tetapi juga membantu meningkatkan efisiensi proses identifikasi morfologi. Oleh karena itu, diperlukan model yang mampu memberikan keseimbangan antara kemampuan ekstraksi fitur dan efisiensi komputasi.

Tan dan Le memperkenalkan EfficientNet sebagai keluarga arsitektur *Convolutional Neural Network* yang menggunakan pendekatan *compound scaling* untuk menyeimbangkan peningkatan kedalaman (*depth*), lebar (*width*), dan resolusi citra secara bersamaan. Pendekatan tersebut memungkinkan EfficientNet menghasilkan performa klasifikasi yang kompetitif dengan jumlah parameter yang relatif lebih sedikit dibandingkan berbagai arsitektur *CNN* sebelumnya [12]. Karakteristik tersebut menjadikan EfficientNet sebagai salah satu kandidat yang sesuai ketika efisiensi komputasi menjadi salah satu pertimbangan utama.

Di sisi lain, Huang et al. [33] memperkenalkan DenseNet yang menerapkan mekanisme *dense connectivity*, yaitu setiap lapisan menerima informasi dari seluruh lapisan sebelumnya. Mekanisme tersebut memungkinkan terjadinya *feature reuse* sehingga informasi visual yang telah dipelajari pada lapisan awal tetap dapat dimanfaatkan pada lapisan berikutnya. Karakteristik ini dinilai berpotensi memberikan representasi fitur yang lebih kaya, terutama pada permasalahan klasifikasi yang melibatkan perbedaan visual yang sangat kecil antar kelas.

Kedua arsitektur tersebut memiliki karakteristik yang berbeda sehingga menarik untuk dibandingkan pada kasus klasifikasi spesies

Pratylenchus. EfficientNet lebih menekankan keseimbangan antara performa klasifikasi dan efisiensi komputasi, sedangkan DenseNet menawarkan kemampuan pemanfaatan kembali fitur melalui mekanisme *dense connectivity*. Oleh karena itu, penelitian ini menggunakan EfficientNetB0 dan DenseNet121 sebagai dua kandidat model yang akan dievaluasi untuk menentukan arsitektur yang paling sesuai dengan karakteristik identifikasi spesies *Pratylenchus*.

Acuan yang dapat diambil dari penelitian ini adalah:

- EfficientNet menawarkan keseimbangan antara performa klasifikasi dan efisiensi komputasi sehingga sesuai untuk penelitian yang mempertimbangkan aspek waktu inferensi.
- DenseNet memiliki mekanisme feature reuse yang berpotensi meningkatkan kemampuan model dalam membedakan karakter morfologi yang memiliki kemiripan visual tinggi.
- Perbedaan karakteristik kedua arsitektur memberikan dasar yang kuat untuk melakukan analisis komparatif dalam menentukan model yang paling sesuai untuk klasifikasi spesies *Pratylenchus*.

2.1.4 Evaluasi Efisiensi Model Menggunakan Waktu Inferensi

Sebagian besar penelitian klasifikasi citra berbasis *Deep Learning* mengevaluasi performa model menggunakan metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score*. Metrik tersebut mampu menggambarkan kemampuan model dalam menghasilkan prediksi yang benar, namun belum sepenuhnya menunjukkan apakah model tersebut sesuai untuk digunakan sebagai sistem bantu pada lingkungan operasional yang membutuhkan hasil identifikasi dalam waktu singkat.

Pada penelitian ini, kebutuhan tersebut berasal dari permasalahan yang telah diidentifikasi pada Bab I. Berdasarkan hasil

diskusi dengan *stakeholder*, *bottleneck* utama dalam *workflow* identifikasi spesies bukan hanya berkaitan dengan ketepatan hasil identifikasi, tetapi juga lamanya waktu yang dibutuhkan untuk melakukan identifikasi morfologi ketika jumlah individu yang harus diamati meningkat. Oleh karena itu, model yang dikembangkan tidak hanya dituntut memiliki performa klasifikasi yang baik, tetapi juga mampu menghasilkan prediksi dalam waktu yang relatif singkat agar dapat membantu meningkatkan efisiensi proses identifikasi.

Karakteristik tersebut menunjukkan bahwa evaluasi model tidak cukup dilakukan hanya berdasarkan metrik performa klasifikasi. Selain akurasi, diperlukan metrik yang dapat menggambarkan efisiensi komputasi model ketika melakukan prediksi. Salah satu metrik yang umum digunakan untuk tujuan tersebut adalah waktu inferensi (*inference time*), yaitu waktu yang diperlukan model untuk menghasilkan prediksi terhadap data masukan setelah proses pelatihan selesai. Penggunaan metrik ini memungkinkan penelitian membandingkan kemampuan setiap model dalam memberikan hasil klasifikasi secara cepat tanpa mengabaikan performa klasifikasinya.

Acuan yang dapat diambil dari penelitian ini adalah:

- Evaluasi model *Deep Learning* perlu mempertimbangkan tidak hanya performa klasifikasi, tetapi juga efisiensi komputasi sesuai dengan tujuan penggunaan sistem.
- Waktu inferensi merupakan metrik yang relevan untuk mengukur kemampuan model dalam menghasilkan prediksi secara cepat setelah proses pelatihan selesai.
- Penelitian ini menggunakan waktu inferensi sebagai salah satu metrik evaluasi karena secara langsung berkaitan dengan kebutuhan *stakeholder* untuk membantu meningkatkan efisiensi proses identifikasi morfologi.

2.2 Tinjauan Teori

2.2.1 Nematoda Parasit Tumbuhan

Nematoda parasit tumbuhan (*plant-parasitic nematodes*) merupakan salah satu kelompok organisme pengganggu tanaman yang memiliki dampak signifikan terhadap produktivitas pertanian di berbagai negara. Meskipun ukuran tubuhnya relatif kecil dan sebagian besar hidup di dalam tanah maupun jaringan tanaman, keberadaan nematoda parasit tumbuhan telah lama diakui sebagai salah satu penyebab utama penurunan hasil produksi pada berbagai komoditas pertanian [4]. Kerugian yang ditimbulkan tidak hanya berupa penurunan kuantitas hasil panen, tetapi juga penurunan kualitas produk pertanian serta peningkatan biaya pengendalian yang harus dikeluarkan oleh petani.

Secara biologis, nematoda merupakan organisme mikroskopis berbentuk cacing yang termasuk ke dalam filum Nematoda. Organisme ini dapat ditemukan pada berbagai habitat seperti tanah, perairan, jaringan hewan, maupun jaringan tumbuhan. Sebagian besar spesies nematoda hidup bebas dan berperan dalam berbagai proses ekologis, namun sebagian lainnya berkembang sebagai organisme parasit yang memanfaatkan tumbuhan maupun hewan sebagai sumber nutrisi [1]. Dari puluhan ribu spesies nematoda yang telah diidentifikasi, lebih dari 4.000 spesies diketahui bersifat parasit terhadap tanaman dan mampu menyebabkan berbagai gangguan pada tanaman budidaya [4].

Nematoda parasit tumbuhan memiliki kemampuan untuk menginfeksi berbagai bagian tanaman, meskipun sebagian besar spesies menyerang sistem perakaran. Aktivitas makan yang dilakukan oleh nematoda menyebabkan kerusakan jaringan tanaman sehingga mengganggu berbagai proses fisiologis yang penting bagi pertumbuhan tanaman. Kerusakan pada sistem perakaran dapat menurunkan kemampuan tanaman dalam menyerap air dan unsur hara yang dibutuhkan untuk proses pertumbuhan dan perkembangan [4], [2]. Akibatnya, tanaman yang terinfeksi sering menunjukkan gejala berupa pertumbuhan terhambat, klorosis, layu, penurunan vigor tanaman, hingga penurunan hasil panen.

Selain menyebabkan kerusakan secara langsung, infeksi nematoda juga dapat meningkatkan kerentanan tanaman terhadap serangan patogen lain. Luka yang terbentuk akibat aktivitas makan nematoda sering kali menjadi pintu masuk bagi jamur, bakteri, maupun mikroorganisme patogen lainnya [2]. Oleh karena itu, dampak kerugian yang ditimbulkan oleh nematoda tidak hanya berasal dari aktivitas nematoda itu sendiri, tetapi juga dari interaksi kompleks antara nematoda dan patogen lain yang menginfeksi tanaman.

Tingkat kerugian yang ditimbulkan oleh nematoda parasit tumbuhan menjadikan kelompok organisme ini sebagai salah satu ancaman utama dalam sektor pertanian global. Jones et al. [4] menempatkan beberapa kelompok nematoda sebagai nematoda parasit tumbuhan yang paling penting secara ekonomi karena penyebarannya yang luas dan kemampuannya menyerang berbagai komoditas pertanian. Kelompok tersebut antara lain *Meloidogyne* (*root-knot nematodes*), *Heterodera* dan *Globodera* (*cyst nematodes*), *Radopholus*, *Bursaphelenchus*, serta *Pratylenchus*.

Besarnya dampak yang ditimbulkan menyebabkan berbagai kegiatan penelitian, diagnosis laboratorium, serta pengelolaan kesehatan tanaman memerlukan informasi yang akurat mengenai spesies nematoda yang ditemukan. Informasi tersebut digunakan untuk menentukan strategi pengendalian yang sesuai, mempelajari distribusi spesies, mengevaluasi tingkat risiko terhadap tanaman tertentu, serta mendukung berbagai kegiatan penelitian yang berkaitan dengan organisme pengganggu tanaman [1]. Dengan demikian, identifikasi nematoda menjadi salah satu tahapan penting dalam berbagai kegiatan yang berkaitan dengan perlindungan tanaman.

Meskipun demikian, proses identifikasi nematoda sering kali menjadi tantangan karena banyak spesies memiliki karakteristik morfologi yang sangat mirip. Pada banyak kasus, perbedaan antarspesies hanya dapat diamati melalui karakter diagnostik tertentu yang berukuran sangat kecil dan memerlukan pengamatan menggunakan mikroskop [1], [2]. Kondisi tersebut menyebabkan

identifikasi nematoda membutuhkan tingkat ketelitian dan pengalaman yang tinggi dari ahli yang melakukan pengamatan.

Tantangan dalam proses identifikasi tersebut mendorong berkembangnya berbagai pendekatan berbasis Computer Vision dan *Deep Learning* untuk membantu proses identifikasi organisme berdasarkan citra biologis [10]. Pendekatan tersebut menawarkan peluang untuk meningkatkan efisiensi proses identifikasi sekaligus mengurangi ketergantungan terhadap proses pengamatan manual yang memerlukan waktu relatif lama. Dalam konteks penelitian ini, pendekatan tersebut dimanfaatkan untuk membantu proses identifikasi spesies nematoda dari genus *Pratylenchus* berdasarkan citra mikroskopis.

2.2.2 Genus *Pratylenchus*

Di antara berbagai kelompok nematoda parasit tumbuhan yang diketahui memiliki dampak ekonomi tinggi, genus *Pratylenchus* merupakan salah satu genus yang paling banyak mendapat perhatian dalam bidang nematologi. Genus ini dikenal sebagai *root lesion nematodes* karena kemampuannya menyebabkan luka (*lesion*) pada jaringan akar tanaman selama proses infeksi [2]. Kerusakan yang ditimbulkan oleh spesies-spesies dalam genus *Pratylenchus* dapat mengganggu pertumbuhan tanaman dan menyebabkan penurunan hasil produksi pada berbagai komoditas pertanian.

Genus *Pratylenchus* termasuk dalam famili *Pratylenchidae* dan terdiri atas lebih dari seratus spesies yang telah dideskripsikan hingga saat ini [2], [3]. Spesies-spesies tersebut tersebar secara luas di berbagai wilayah dunia dan ditemukan pada berbagai ekosistem pertanian. Penyebaran yang luas tersebut menyebabkan *Pratylenchus* menjadi salah satu kelompok nematoda yang paling sering ditemukan dalam kegiatan survei, penelitian, maupun diagnosis organisme pengganggu tanaman.

Salah satu karakteristik utama genus *Pratylenchus* adalah sifatnya sebagai *migratory endoparasitic nematodes*. Berbeda dengan beberapa kelompok nematoda lain yang membentuk struktur khusus pada akar tanaman, *Pratylenchus* mampu bergerak masuk dan keluar dari jaringan akar selama proses infeksi [2]. Aktivitas tersebut memungkinkan nematoda untuk berpindah antar bagian jaringan tanaman sambil melakukan aktivitas makan yang menyebabkan kerusakan jaringan secara bertahap.

Proses infeksi biasanya diawali dengan penetrasi nematoda ke dalam jaringan akar menggunakan stilet yang dimilikinya. Setelah memasuki jaringan tanaman, nematoda bergerak di antara sel-sel akar dan melakukan aktivitas makan yang menyebabkan kerusakan jaringan. Kerusakan tersebut menghasilkan luka berwarna kecokelatan hingga kehitaman pada akar yang dikenal sebagai *root lesions* [2]. Semakin tinggi tingkat infestasi yang terjadi, semakin besar pula tingkat kerusakan yang dapat ditimbulkan pada sistem perakaran tanaman.

Kerusakan akar akibat infeksi *Pratylenchus* dapat menghambat kemampuan tanaman dalam menyerap air dan unsur hara. Akibatnya, tanaman yang terinfeksi sering menunjukkan gejala berupa pertumbuhan terhambat, penurunan vigor, penurunan kualitas hasil panen, serta penurunan produktivitas secara keseluruhan [2]. Selain itu, luka yang terbentuk pada akar juga dapat meningkatkan kerentanan tanaman terhadap infeksi patogen lain sehingga memperparah tingkat kerusakan yang terjadi.

Genus *Pratylenchus* diketahui memiliki kisaran tanaman inang yang sangat luas. Berbagai spesies dalam genus ini dilaporkan mampu menginfeksi tanaman pangan, tanaman hortikultura, tanaman perkebunan, hingga tanaman hias [2]. Luasnya kisaran inang tersebut

menyebabkan *Pratylenchus* menjadi salah satu kelompok nematoda yang memiliki dampak ekonomi penting pada berbagai sektor pertanian.

Meskipun berada dalam genus yang sama, spesies-spesies *Pratylenchus* dapat menunjukkan karakteristik biologis yang berbeda. Perbedaan tersebut dapat mencakup kisaran tanaman inang, tingkat patogenisitas, kemampuan adaptasi terhadap lingkungan, maupun distribusi geografis [2], [3]. Oleh karena itu, identifikasi yang dilakukan hanya sampai pada tingkat genus sering kali belum cukup untuk memenuhi kebutuhan penelitian maupun pengelolaan organisme pengganggu tanaman secara efektif.

Dalam kegiatan penelitian maupun diagnosis laboratorium, identifikasi hingga tingkat spesies menjadi sangat penting karena informasi spesies dapat digunakan untuk memahami karakteristik biologis suatu nematoda secara lebih spesifik. Informasi tersebut mendukung kajian mengenai hubungan antara nematoda dan tanaman inangnya, pola penyebaran spesies, serta penyusunan strategi pengelolaan yang lebih tepat [1], [2].

Namun demikian, identifikasi spesies dalam genus *Pratylenchus* bukanlah pekerjaan yang mudah. Banyak spesies menunjukkan kemiripan morfologi yang sangat tinggi sehingga sulit dibedakan hanya melalui pengamatan visual sederhana. Perbedaan antarspesies sering kali terletak pada karakter diagnostik tertentu yang berukuran sangat kecil dan memerlukan pengamatan yang cermat menggunakan mikroskop [2], [3]. Kondisi tersebut menyebabkan proses identifikasi membutuhkan tingkat ketelitian dan pengalaman yang tinggi dari ahli nematoda.

Tingginya kemiripan morfologi antarspesies menjadikan identifikasi spesies *Pratylenchus* sebagai salah satu permasalahan

yang menantang dalam bidang nematologi. Tantangan tersebut menjadi semakin relevan pada penelitian ini karena objek yang diklasifikasikan adalah *Pratylenchus bolivianus* dan *Pratylenchus pseudocoffeae*, yaitu dua spesies yang berasal dari genus yang sama dan memiliki karakteristik morfologi yang relatif serupa. Oleh karena itu, diperlukan suatu pendekatan yang mampu mempelajari fitur-fitur visual yang bersifat diskriminatif sehingga proses identifikasi spesies dapat dilakukan secara lebih akurat, konsisten, dan efisien.

2.2.3 *Pratylenchus bolivianus*

Pratylenchus bolivianus merupakan salah satu spesies nematoda parasit tumbuhan yang termasuk ke dalam genus *Pratylenchus*. Sebagai anggota kelompok *root lesion nematodes*, spesies ini memiliki kemampuan untuk menginfeksi sistem perakaran tanaman dan menyebabkan kerusakan jaringan yang dapat mengganggu pertumbuhan tanaman inang [2]. Keberadaan spesies ini telah dilaporkan pada berbagai tanaman dan menjadi bagian dari kelompok nematoda yang memiliki relevansi dalam bidang perlindungan tanaman maupun penelitian nematologi.

Sebagaimana spesies lain dalam genus *Pratylenchus*, *P. bolivianus* memiliki tubuh berbentuk vermiform atau menyerupai cacing dengan ukuran yang relatif kecil sehingga hanya dapat diamati menggunakan mikroskop. Identifikasi spesies ini umumnya dilakukan melalui pendekatan morfologi dan morfometri dengan mengamati berbagai karakter diagnostik yang terdapat pada tubuh nematoda. Karakter yang diamati dapat mencakup bentuk tubuh, panjang tubuh, bentuk daerah kepala, panjang stilet, posisi vulva, serta bentuk ekor [2], [3].

Meskipun karakter-karakter tersebut dapat digunakan sebagai dasar dalam proses identifikasi, perbedaan antara *P. bolivianus* dan spesies lain dalam genus yang sama sering kali bersifat sangat halus. Pada

banyak kasus, identifikasi memerlukan kombinasi antara pengamatan morfologi, pengukuran morfometri, dan konfirmasi menggunakan pendekatan molekuler untuk memperoleh tingkat kepercayaan yang lebih tinggi [1], [3]. Kondisi tersebut menunjukkan bahwa identifikasi spesies *Pratylenchus* tidak selalu dapat dilakukan secara mudah melalui pengamatan visual sederhana.

Tantangan identifikasi menjadi semakin besar karena banyak spesies dalam genus *Pratylenchus* memiliki karakteristik morfologi yang saling tumpang tindih. Variasi alami yang muncul pada populasi yang berbeda juga dapat menyebabkan rentang karakter morfologi antarspesies menjadi semakin sulit dibedakan [2]. Akibatnya, proses identifikasi sering kali membutuhkan pengalaman dan keahlian khusus dari ahli nematoda yang melakukan pengamatan.

Dalam penelitian ini, *P. bolivianus* dipilih sebagai salah satu spesies yang digunakan pada proses klasifikasi menggunakan model *Deep Learning*. Pemilihan spesies ini didasarkan pada ketersediaan citra mikroskopis yang telah melalui proses identifikasi oleh ahli nematoda serta tingginya tingkat kemiripan morfologi dengan *Pratylenchus pseudocoffeae*. Karakteristik tersebut menjadikan *P. bolivianus* sesuai untuk mengevaluasi kemampuan model dalam membedakan spesies *Pratylenchus* yang memiliki kemiripan morfologi tinggi. Kemampuan tersebut diharapkan dapat membantu mempercepat proses identifikasi spesies tanpa mengurangi kualitas hasil klasifikasi.

Citra yang digunakan pada penelitian ini merupakan citra mikroskopis seluruh tubuh (*whole-body microscopic images*) sehingga informasi morfologi yang tersedia tidak hanya berasal dari satu bagian tubuh tertentu, tetapi mencakup keseluruhan struktur tubuh nematoda. Dengan karakteristik tersebut, model diharapkan mampu mempelajari

berbagai fitur visual yang relevan untuk membedakan *P. bolivianus* dari spesies lain yang memiliki karakteristik morfologi serupa.

Penggunaan citra seluruh tubuh juga memberikan tantangan tersendiri karena model harus mampu menentukan bagian-bagian morfologi yang paling informatif untuk proses klasifikasi secara otomatis. Berbeda dengan proses identifikasi manual yang berfokus pada karakter diagnostik tertentu, model *Deep Learning* mempelajari sendiri fitur-fitur visual yang paling relevan berdasarkan data pelatihan. Oleh karena itu, kemampuan model dalam mempelajari representasi fitur yang bersifat diskriminatif menjadi salah satu faktor penting untuk menghasilkan klasifikasi yang akurat serta mendukung proses identifikasi spesies secara lebih efisien.

2.2.4 *Pratylenchus pseudocoffeae*

Pratylenchus pseudocoffeae merupakan salah satu spesies nematoda parasit tumbuhan yang termasuk dalam genus *Pratylenchus*. Spesies ini memiliki karakteristik biologis yang serupa dengan anggota genus lainnya, yaitu mampu menginfeksi jaringan akar tanaman dan menyebabkan kerusakan yang dapat mengganggu pertumbuhan serta produktivitas tanaman inang [2]. Sebagai bagian dari kelompok *root lesion nematodes*, keberadaan *P. pseudocoffeae* menjadi penting untuk diperhatikan dalam berbagai kegiatan penelitian maupun diagnosis organisme pengganggu tanaman.

Identifikasi *P. pseudocoffeae* secara tradisional dilakukan melalui pengamatan karakter morfologi dan morfometri menggunakan mikroskop. Berbagai karakter diagnostik seperti bentuk tubuh, struktur kepala, panjang stilet, posisi vulva, serta bentuk ekor digunakan sebagai dasar dalam proses identifikasi spesies [2], [3]. Namun demikian, karakter-karakter tersebut sering kali menunjukkan kemiripan yang tinggi dengan spesies lain dalam genus *Pratylenchus*

sehingga proses identifikasi memerlukan pengamatan yang teliti dan pengalaman yang memadai.

Salah satu tantangan utama dalam identifikasi *P. pseudocoffeae* adalah tingginya tingkat kemiripan morfologi dengan spesies lain yang masih berada dalam genus yang sama. Pada beberapa kasus, perbedaan antarspesies hanya ditemukan pada karakter diagnostik tertentu yang memiliki ukuran sangat kecil atau menunjukkan variasi yang sempit [2]. Akibatnya, proses identifikasi sering kali membutuhkan waktu yang cukup lama karena setiap karakter harus diamati dan dievaluasi secara cermat sebelum keputusan identifikasi dapat dibuat.

Dalam kegiatan penelitian dan diagnosis laboratorium, ketepatan identifikasi *P. pseudocoffeae* menjadi sangat penting karena informasi spesies dapat digunakan untuk mendukung berbagai analisis biologis maupun kegiatan pengelolaan organisme pengganggu tanaman. Kesalahan identifikasi berpotensi menyebabkan kesalahan interpretasi terhadap data yang diperoleh serta memengaruhi keputusan yang diambil berdasarkan hasil identifikasi tersebut [1].

Pada penelitian ini, *P. pseudocoffeae* dipilih sebagai spesies pembanding terhadap *Pratylenchus bolivianus* dalam proses klasifikasi menggunakan model *Deep Learning*. Pemilihan spesies ini didasarkan pada ketersediaan citra mikroskopis yang telah melalui proses identifikasi oleh ahli nematoda serta tingginya kemiripan morfologi dengan *P. bolivianus*. Karakteristik tersebut menjadikan *P. pseudocoffeae* sesuai untuk mengevaluasi kemampuan model dalam membedakan spesies *Pratylenchus* yang memiliki kemiripan morfologi tinggi.

Pemilihan *P. pseudocoffeae* dan *P. bolivianus* sebagai objek penelitian didasarkan pada tingginya kemiripan morfologi yang dimiliki oleh kedua spesies tersebut. Berbeda dengan klasifikasi antar genus yang umumnya memiliki perbedaan visual yang lebih jelas,

klasifikasi kedua spesies ini menuntut model untuk mengenali karakteristik morfologi yang bersifat lebih halus dan diskriminatif. Oleh karena itu, permasalahan yang dihadapi pada penelitian ini termasuk ke dalam kategori *fine-grained image classification* [8], [9].

Karakteristik tersebut menjadikan kedua spesies sebagai objek yang sesuai untuk mengevaluasi kemampuan model *Deep Learning* dalam membantu proses identifikasi spesies nematoda berdasarkan citra mikroskopis. Keberhasilan model dalam membedakan *P. pseudocoffeae* dan *P. bolivianus* diharapkan dapat menunjukkan potensi pemanfaatan teknologi *Computer Vision* dan *Deep Learning* untuk mendukung proses identifikasi spesies secara lebih cepat dan konsisten tanpa mengurangi kualitas hasil klasifikasi.

2.2.5 Deep Learning

Deep Learning merupakan salah satu cabang dari *Machine Learning* yang menggunakan jaringan saraf tiruan (*Artificial Neural Network*) dengan banyak lapisan (*deep neural network*) untuk mempelajari representasi data secara otomatis [6]. Berbeda dengan pendekatan *Machine Learning* tradisional yang umumnya memerlukan proses ekstraksi fitur secara manual, *Deep Learning* mampu mempelajari fitur-fitur yang relevan langsung dari data yang digunakan selama proses pelatihan.

Kemampuan tersebut menjadi salah satu alasan utama meningkatnya penggunaan *Deep Learning* pada berbagai permasalahan *Computer Vision*. Melalui proses pembelajaran berlapis, model dapat mengenali pola visual mulai dari karakteristik sederhana seperti tepi dan tekstur hingga karakteristik yang lebih kompleks seperti bentuk objek dan hubungan antarbagian objek [6].

Salah satu keunggulan utama *Deep Learning* adalah kemampuannya dalam mempelajari representasi fitur yang bersifat hierarkis. Pada lapisan awal, model biasanya mempelajari fitur-fitur dasar seperti garis, sudut, dan tekstur. Informasi tersebut kemudian dikombinasikan

pada lapisan yang lebih dalam untuk membentuk representasi visual yang semakin kompleks. Dengan mekanisme tersebut, model dapat mengenali objek berdasarkan berbagai karakteristik visual yang terdapat pada data masukan [6].

Keberhasilan *Deep Learning* telah ditunjukkan pada berbagai bidang aplikasi, termasuk klasifikasi citra medis, pengenalan wajah, kendaraan otonom, deteksi penyakit tanaman, serta identifikasi organisme biologis [6], [10]. Dalam banyak kasus, performa model *Deep Learning* mampu melampaui pendekatan klasifikasi konvensional karena kemampuan model dalam mengekstraksi informasi visual yang kompleks secara otomatis.

Dalam penelitian ini, *Deep Learning* digunakan karena mampu mempelajari representasi fitur yang kompleks pada permasalahan *fine-grained image classification*. Tingginya kemiripan morfologi antara *Pratylenchus bolivianus* dan *Pratylenchus pseudocoffeae* menyebabkan model perlu mengenali karakteristik visual yang bersifat halus dan diskriminatif agar kedua spesies dapat dibedakan secara akurat.

Pendekatan berbasis *Deep Learning* dinilai sesuai untuk mengatasi permasalahan tersebut karena mampu mempelajari representasi fitur yang lebih kompleks dibandingkan metode klasifikasi tradisional. Melalui proses pembelajaran dari data pelatihan, model dapat mengenali pola-pola visual yang membedakan kedua spesies meskipun perbedaannya relatif kecil.

Selain itu, *Deep Learning* juga memiliki kemampuan untuk melakukan proses inferensi secara cepat setelah model selesai dilatih. Karakteristik ini sejalan dengan tujuan penelitian yang tidak hanya berfokus pada ketepatan klasifikasi, tetapi juga pada efisiensi waktu identifikasi. Setelah proses pelatihan selesai, model dapat menghasilkan prediksi spesies dalam hitungan detik sehingga

berpotensi membantu mengurangi bottleneck yang selama ini terjadi pada tahap identifikasi morfologi.

Oleh karena itu, *Deep Learning* dipilih sebagai pendekatan utama pada penelitian ini untuk melakukan klasifikasi spesies *Pratylenchus* berdasarkan citra mikroskopis. Melalui kemampuan pembelajaran fitur secara otomatis dan proses inferensi yang cepat, pendekatan ini diharapkan mampu membantu mempercepat proses identifikasi spesies tanpa mengurangi kualitas hasil klasifikasi.

2.2.6 *Convolutional Neural Network (CNN)*

Convolutional Neural Network (CNN) merupakan salah satu arsitektur *Deep Learning* yang dirancang khusus untuk memproses data berbentuk citra. *CNN* menjadi pendekatan yang paling banyak digunakan dalam berbagai tugas *Computer Vision* karena memiliki kemampuan untuk mengekstraksi fitur visual secara otomatis tanpa memerlukan proses perancangan fitur secara manual [6].

Berbeda dengan metode klasifikasi citra konvensional yang umumnya memerlukan tahap ekstraksi fitur menggunakan teknik tertentu sebelum proses klasifikasi dilakukan, *CNN* mampu mempelajari representasi fitur secara langsung dari data citra yang digunakan selama proses pelatihan. Kemampuan tersebut memungkinkan model mengenali berbagai pola visual yang relevan untuk membedakan objek dari kelas yang berbeda.

Secara umum, *CNN* tersusun atas beberapa jenis lapisan utama, yaitu *convolution layer*, *pooling layer*, dan *fully connected layer*. *Convolution layer* berfungsi untuk mengekstraksi fitur melalui proses konvolusi menggunakan kernel atau filter tertentu. Pada tahap awal, filter yang dipelajari model biasanya menangkap fitur sederhana seperti tepi, garis, dan tekstur. Seiring bertambahnya kedalaman

jaringan, fitur yang dipelajari menjadi semakin kompleks dan mampu merepresentasikan karakteristik objek yang lebih spesifik [6].

Setelah proses konvolusi dilakukan, fitur yang dihasilkan umumnya diproses menggunakan fungsi aktivasi *nonlinier* seperti *Rectified Linear Unit (ReLU)*. Fungsi aktivasi ini memungkinkan model mempelajari hubungan yang lebih kompleks dibandingkan transformasi linier sederhana. Selanjutnya, *pooling layer* digunakan untuk mengurangi dimensi fitur sehingga kebutuhan komputasi dapat ditekan tanpa menghilangkan informasi penting secara signifikan.

Pada bagian akhir jaringan, fitur yang telah diekstraksi diteruskan ke lapisan klasifikasi untuk menghasilkan prediksi kelas. Seluruh parameter model dipelajari secara otomatis melalui proses optimasi berdasarkan data pelatihan yang digunakan [6].

Keberhasilan *CNN* telah ditunjukkan pada berbagai permasalahan klasifikasi citra, termasuk pada bidang pertanian, kedokteran, dan biologi [6], [10]. Kemampuan *CNN* dalam mengenali pola visual yang kompleks menjadikannya sangat sesuai untuk menganalisis citra mikroskopis yang sering kali memiliki karakteristik visual yang sulit diamati secara langsung oleh manusia.

Dalam penelitian ini, *CNN* digunakan sebagai fondasi utama dalam pengembangan model klasifikasi spesies *Pratylenchus*. Arsitektur EfficientNetB0 dan DenseNet121 yang digunakan merupakan pengembangan dari konsep *CNN* yang telah dioptimalkan untuk menghasilkan kemampuan ekstraksi fitur yang lebih baik. Dengan demikian, pemahaman mengenai prinsip kerja *CNN* menjadi dasar penting dalam memahami mekanisme klasifikasi yang dilakukan oleh model pada penelitian ini.

2.2.7 Transfer Learning

Transfer Learning merupakan pendekatan pembelajaran yang memanfaatkan pengetahuan yang telah dipelajari oleh suatu model pada tugas sebelumnya untuk membantu menyelesaikan tugas baru yang masih memiliki keterkaitan [6]. Pendekatan ini banyak digunakan pada berbagai penelitian klasifikasi citra karena mampu menghasilkan performa yang baik meskipun jumlah data pelatihan relatif terbatas.

Pada pendekatan konvensional, model *Deep Learning* dilatih dari awal (*training from scratch*) menggunakan seluruh data yang tersedia. Namun demikian, pelatihan dari awal umumnya membutuhkan jumlah data yang sangat besar serta sumber daya komputasi yang tinggi agar model dapat mempelajari representasi fitur secara optimal [6]. Ketika jumlah data terbatas, model yang dilatih dari awal berisiko mengalami *overfitting* dan menghasilkan kemampuan generalisasi yang kurang baik.

Transfer Learning menawarkan solusi terhadap permasalahan tersebut dengan memanfaatkan model yang telah dilatih sebelumnya pada dataset berskala besar, seperti *ImageNet*. Dataset *ImageNet* terdiri atas jutaan citra yang mencakup ribuan kategori objek sehingga model yang telah dilatih pada dataset tersebut umumnya telah mempelajari berbagai representasi fitur visual yang bersifat umum [6].

Fitur-fitur yang dipelajari pada tahap awal pelatihan biasanya berupa karakteristik dasar seperti tepi, tekstur, bentuk, dan pola visual lainnya. Karakteristik tersebut bersifat universal dan dapat dimanfaatkan kembali pada berbagai tugas klasifikasi citra yang berbeda. Oleh karena itu, model tidak perlu mempelajari seluruh representasi visual dari awal ketika diterapkan pada dataset baru.


Dalam implementasinya, *Transfer Learning* umumnya dilakukan melalui dua tahap utama, yaitu *feature extraction* dan *fine-tuning*.

Pada tahap *feature extraction*, lapisan *backbone* dibekukan (*frozen*) sehingga bobot yang telah dipelajari sebelumnya tidak mengalami perubahan. Hanya lapisan klasifikasi baru yang dilatih menggunakan dataset penelitian. Tahap ini memungkinkan model beradaptasi terhadap tugas klasifikasi baru dengan cepat.

Setelah model mencapai performa yang stabil, dilakukan tahap *fine-tuning* dengan membuka sebagian lapisan backbone untuk dilatih kembali menggunakan learning rate yang lebih kecil. Pendekatan ini memungkinkan model menyesuaikan representasi fitur yang telah dipelajari sebelumnya dengan karakteristik spesifik dataset penelitian [6].

Berbagai penelitian menunjukkan bahwa *Transfer Learning* mampu meningkatkan performa klasifikasi pada berbagai kasus citra biologis ketika jumlah data pelatihan relatif terbatas [10], [11]. Dengan karakteristik tersebut, *Transfer Learning* menjadi salah satu pendekatan yang banyak digunakan dalam pengembangan model klasifikasi citra karena mampu memanfaatkan representasi fitur yang telah dipelajari sebelumnya untuk menyelesaikan tugas klasifikasi baru secara lebih efektif.

2.2.8 EfficientNetB0



Gambar 2.1 Arsitektur EfficientNetB0 [15]

EfficientNetB0 merupakan salah satu arsitektur *Convolutional Neural Network (CNN)* yang diperkenalkan oleh Tan dan Le pada tahun 2019 melalui pendekatan *compound scaling* [12]. Arsitektur ini dikembangkan untuk mengatasi keterbatasan metode penskalaan model konvensional yang umumnya hanya berfokus pada peningkatan kedalaman (*depth*), lebar (*width*), atau resolusi citra (*resolution*) secara terpisah.

Sebelum diperkenalkannya EfficientNet, peningkatan performa model *CNN* umumnya dilakukan dengan menambah jumlah lapisan atau memperbesar ukuran jaringan. Meskipun pendekatan tersebut mampu meningkatkan akurasi, konsekuensinya adalah meningkatnya kebutuhan komputasi dan jumlah parameter secara signifikan. Kondisi tersebut menyebabkan model menjadi lebih berat dan membutuhkan waktu inferensi yang lebih lama.

EfficientNet diperkenalkan dengan konsep *compound scaling*, yaitu metode penskalaan yang meningkatkan kedalaman jaringan, lebar jaringan, dan resolusi citra secara bersamaan menggunakan koefisien yang telah dioptimalkan [12]. Melalui pendekatan tersebut, EfficientNet mampu mencapai keseimbangan yang lebih baik antara performa klasifikasi dan efisiensi komputasi.


Selain menggunakan *compound scaling*, EfficientNetB0 juga memanfaatkan blok *MBConv* (*Mobile Inverted Bottleneck Convolution*) yang dikombinasikan dengan mekanisme *Squeeze-and-Excitation (SE)*. Blok *MBConv* dirancang untuk meningkatkan efisiensi proses ekstraksi fitur dengan jumlah parameter yang relatif kecil, sedangkan mekanisme *SE* membantu model memberikan perhatian yang lebih besar terhadap fitur-fitur yang dianggap penting selama proses pembelajaran [12].

Berbagai penelitian menunjukkan bahwa EfficientNet mampu menghasilkan performa klasifikasi yang kompetitif dengan kebutuhan komputasi yang lebih rendah dibandingkan banyak arsitektur *CNN* lainnya [12], [13]. Karakteristik tersebut menjadikan EfficientNet menarik untuk digunakan pada berbagai aplikasi yang memerlukan keseimbangan antara akurasi dan efisiensi, termasuk pada perangkat bergerak maupun berbagai aplikasi yang membutuhkan waktu inferensi cepat.

Dalam penelitian ini, EfficientNetB0 digunakan sebagai salah satu model yang dievaluasi dalam proses klasifikasi spesies *Pratylenchus*. Pemilihan arsitektur ini didasarkan pada kemampuannya menghasilkan keseimbangan antara performa klasifikasi dan efisiensi komputasi. Dengan jumlah parameter yang relatif lebih sedikit dibandingkan banyak arsitektur *CNN* lainnya, EfficientNetB0 diharapkan mampu menghasilkan waktu inferensi yang cepat tanpa mengurangi kemampuan model dalam membedakan spesies yang memiliki kemiripan morfologi tinggi.

Selain itu, penggunaan EfficientNetB0 memungkinkan evaluasi terhadap sejauh mana arsitektur yang dirancang dengan fokus pada efisiensi komputasi mampu menyelesaikan permasalahan *fine-grained image classification* pada citra mikroskopis nematoda. Hasil evaluasi tersebut kemudian dibandingkan dengan model lain yang memiliki karakteristik arsitektur berbeda untuk memperoleh gambaran yang lebih komprehensif mengenai solusi yang paling sesuai dengan kebutuhan penelitian.

2.2.9 DenseNet121



Gambar 2.2 Arsitektur DenseNet121 [16]

DenseNet121 merupakan arsitektur *CNN* yang diperkenalkan oleh Huang dkk. melalui konsep *Densely Connected Convolutional Networks* atau *DenseNet* [14]. Berbeda dengan arsitektur *CNN* konvensional yang hanya menghubungkan satu lapisan dengan lapisan berikutnya, *DenseNet* menghubungkan setiap lapisan dengan seluruh lapisan sebelumnya dalam satu blok jaringan.

Melalui mekanisme tersebut, setiap lapisan dapat memanfaatkan informasi yang telah dipelajari oleh seluruh lapisan sebelumnya. Pendekatan ini dikenal sebagai *dense connection* dan menjadi karakteristik utama yang membedakan *DenseNet* dari berbagai arsitektur *CNN* lainnya [14].

Salah satu keuntungan utama dari *dense connection* adalah kemampuan untuk mempertahankan aliran informasi selama proses pelatihan. Pada jaringan yang sangat dalam, proses pembelajaran seringkali menghadapi permasalahan *vanishing gradient*, yaitu kondisi ketika informasi gradien menjadi semakin kecil sehingga proses pembaruan bobot menjadi kurang efektif. *DenseNet* membantu mengatasi permasalahan tersebut dengan menyediakan jalur langsung

bagi aliran informasi dan gradien menuju lapisan yang lebih awal [14].

Selain membantu proses optimasi, *DenseNet* juga menerapkan konsep *feature reuse*, yaitu penggunaan kembali fitur yang telah dipelajari pada lapisan sebelumnya. Dengan pendekatan tersebut, model tidak perlu mempelajari representasi fitur yang sama secara berulang sehingga penggunaan parameter menjadi lebih efisien dibandingkan arsitektur yang hanya mengandalkan penambahan jumlah lapisan [14].

Karakteristik tersebut menjadikan *DenseNet* memiliki kemampuan yang baik dalam mengekstraksi fitur-fitur kompleks yang diperlukan pada berbagai tugas klasifikasi citra. Berbagai penelitian menunjukkan bahwa *DenseNet* mampu menghasilkan performa yang kompetitif pada berbagai benchmark klasifikasi citra serta memiliki kemampuan generalisasi yang baik terhadap data baru [14].

Dalam penelitian ini, *DenseNet121* digunakan sebagai model pembandingan terhadap *EfficientNetB0*. Pemilihan *DenseNet121* didasarkan pada kemampuannya dalam mempertahankan dan memanfaatkan kembali informasi fitur selama proses ekstraksi fitur. Kemampuan tersebut dinilai relevan dengan karakteristik permasalahan yang dihadapi pada penelitian ini, yaitu membedakan dua spesies *Pratylenchus* yang memiliki kemiripan morfologi tinggi.

Pada kasus *fine-grained image classification*, perbedaan antar kelas sering kali hanya muncul pada karakteristik visual tertentu yang bersifat sangat halus. Oleh karena itu, kemampuan model dalam mempertahankan informasi visual yang relevan menjadi faktor penting dalam proses klasifikasi. Karakteristik *feature reuse* yang dimiliki *DenseNet121* memungkinkan model memanfaatkan kembali

informasi dari lapisan sebelumnya sehingga representasi fitur yang dipelajari menjadi lebih kaya dan lebih diskriminatif.



UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA