

BAB II

STUDI LITERATUR

2.1 PRISMA

Alat panduan atau kerangka kerja yang digunakan untuk melakukan penelitian tentang ulasan sistematis dan metaanalisis adalah (PRISMA), yang merupakan singkatan dari *Preferensial Reporting Items for Systematic Reviews And MetaAnalyses*. Diagram alir, yang memetakan jumlah catatan yang diidentifikasi, disertakan, dan dikecualikan, serta alasan mengapa catatan tersebut dikecualikan, digunakan untuk menggambarkan aliran informasi melalui fase-fase yang berbeda dari tinjauan sistematis (Page et al., 2021). (Yepes-Nuñez et al., 2021) Menurut Yepes-Nuñez et al., (2021) Diagram alir, yang menggambarkan aliran informasi melalui tahapan yang berbeda dari tinjauan sistematis, dikenal sebagai prisma diagram. Ini menunjukkan berapa banyak catatan yang diidentifikasi, dimasukkan, dan dikecualikan, serta alasan mengapa mereka dikecualikan. Jenis ulasan (baru atau diperbarui) dan sumber yang digunakan untuk mengidentifikasi penelitian menentukan jenis templat yang tersedia. Proses pembuatan penilaian literatur sistematis (PRISMA) terdiri dari empat langkah:

1. Identifikasi jurnal yang akan dimasukkan dalam metaanalisis;
2. *Screening* (Penyaringan), penyaringan atau pemilihan data;
3. *Eligibility* (Kelayakan), menentukan artikel yang akan digunakan sebagai bahan penilaian literatur; dan
4. *Inclusion* (Inklusi), menggabungkan dan melaporkan hasil.

2.1.1 Identifikasi

Identifikasi adalah proses yang bertujuan untuk memeriksa dan menganalisa; dalam proses ini, penulis mengidentifikasi masalah penelitian (masalah penelitian) untuk menentukan kualitas penelitian (Mohamed et al., 2020).

2.1.2 Screening

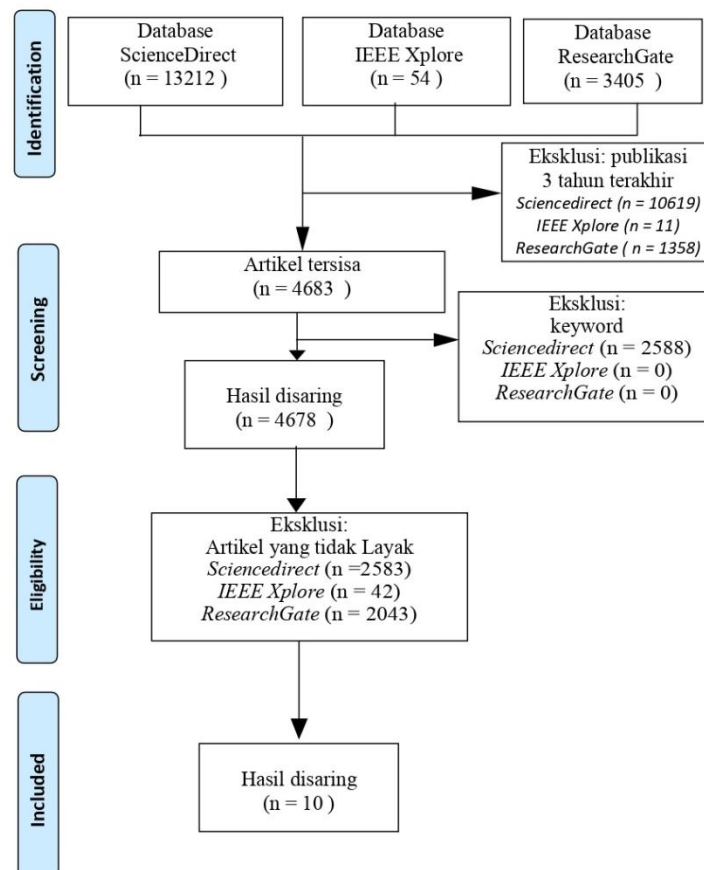
Penyaringan, juga dikenal sebagai penyaringan, adalah proses yang memungkinkan artikel dimasukkan atau dikeluarkan berdasarkan kriteria yang ditetapkan oleh penulis (Mohamed et al., 2020).

2.1.3 Eligibility

Tahap kelayakan adalah pemeriksaan kelayakan artikel. Semua artikel diperiksa untuk memastikan bahwa mereka memenuhi kriteria inklusi dan sejalan dengan tujuan penelitian saat ini (Mohamed et al., 2020).

2.1.4 Inclusion

Included adalah tahap terakhir dari PRISMA (*Preferred Reporting Items for Systematic Reviews And Meta-Analyses*) flow diagram. Artikel harus dimasukkan setelah memenuhi persyaratan analisis (Mohamed et al., 2020). diagram prisma dapat dilihat pada gambar 2.1



Gambar 2.1 Prisma Diagram

Berdasarkan gambar 2.1 penulis mengumpulkan data dari beberapa database seperti *ScienceDirect*, *IEEE*, dan *ResearchGate* dengan melalui beberapa proses, seperti :

1. Identifikasi

Pada saat melakukan identifikasi dengan menggunakan topik yang telah disesuaikan, yaitu "*rose leaf disease*" untuk pencarian data, didapatkan jumlah artikel yang berbeda dari setiap database yang digunakan. Dari *ScienceDirect* ditemukan 13,212 artikel, dari *IEEE* ditemukan 54 artikel, dan dari *ResearchGate* ditemukan 3,405 artikel.

2. *Screening*

Proses penyaringan artikel yang paling relevan dengan topik yang akan diteliti dikenal sebagai *screening* atau pemilihan data. Beberapa tahapan *screening* dilakukan:

- a. Pembatasan tahunan. Peneliti membatasi pembatasan pada 3 tahun terakhir 2021–2023 dengan menggunakan jurnal internasional untuk mendapatkan sumber dan data terbaru. Artikel terkumpul sebanyak 4683
- b. Pengecekan berdasarkan keyword artikel jurnal artikel terkumpul sebanyak 4678

3. *Eligibility*

Tahap *Eligibility* dilakukan setelah tahap *Screening* selesai. Ini adalah proses menyesuaikan atau mengevaluasi data pencarian menggunakan kriteria inklusi untuk mendapatkan dokumen atau data yang sesuai dengan kebutuhan peneliti. Pada tahap ini, penulis memeriksa kembali 4678 artikel yang relevan dengan penelitian dan menemukan 10 artikel yang relevan tentang penerapan *rose leaf disease*.


4. *Included*

Included ini merupakan tahap terakhir dari tahapan peninjauan sistematis. Tahap ini mencakup 10 artikel yang memenuhi kriteria kelayakan.

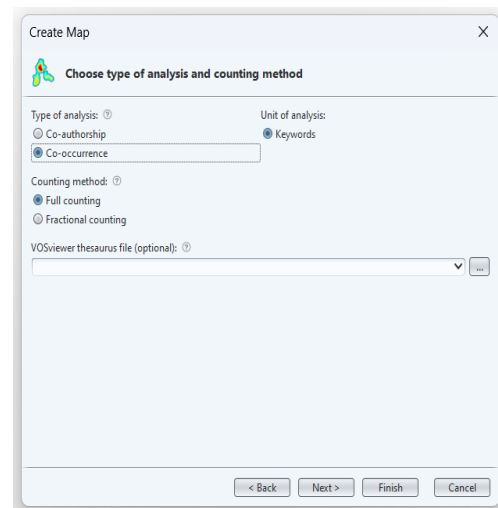
2.2 VOS Viewer

VOS Viewer, atau disebut juga VV, adalah perangkat lunak yang digunakan untuk memvisualisasikan peta bibliometric (Barra & Zotti, 2017), atau kumpulan data yang berisi *field bibliografi* seperti judul, pengarang, jurnal, dan lain-lain. Dalam dunia penelitian, VV digunakan untuk analisis bibliometrik, pemetaan topik untuk penelitian terbaru, menemukan referensi yang paling banyak digunakan dalam bidang tertentu, dan lain-lain. VV dapat membaca dataset dari berbagai situs jurnal online seperti *Google Scholar*, *Web of Science*, *Scopus*, *Dimension*, dan *Pubmed* (Mundt & Mundt, 2020).

Gambar 2.1 menunjukkan tahapan peninjauan sistematis, di mana penulis mengumpulkan 16671 hasil artikel dari 3 database *ScienceDirect*, *ResearchGate*, dan *IEEE*. Namun, pengumpulan hasil artikel menjadi 4678 selama tahap skrining, dan 4678 artikel ini dapat divisualisasikan dengan VOS Viewer dengan melakukan tahap pembersihan kembali bagi *keyword* yang tidak relevan. tahapanya sebagai berikut:

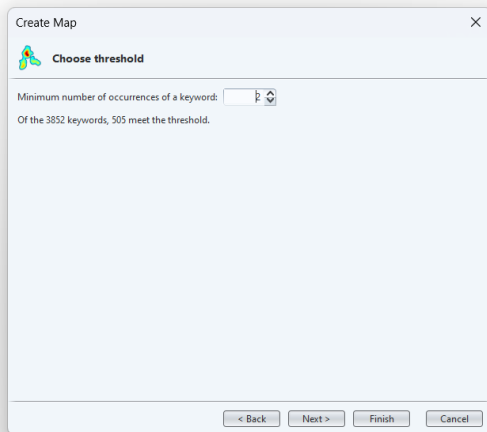


Gambar 2.2 *Input file ris*

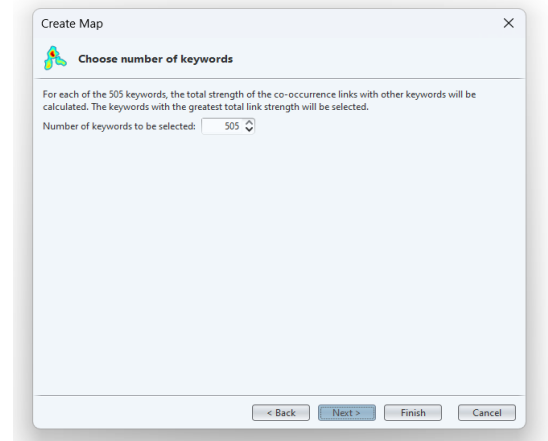


Gambar 2.3 *Memilih type counting*

Setelah membuat map baru, inputkan semua file ris dari 3 database tersebut seperti pada gambar 2.2, setelah itu pilih *co-occurrence* agar dapat memilih unit *type* berdasarkan *keywords*, pilih *full counting* untuk menghitung kesesuaian dengan dokumen yang dilihat atau diuji

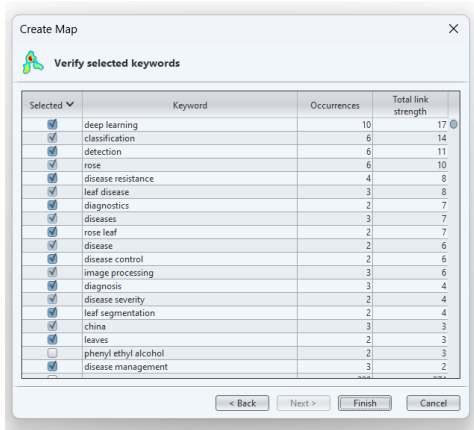


Gambar 2.4 Menentukan jumlah *threshold*




Gambar 2.5 Minimum *keyword*

Tahap selanjutnya pada gambar 2.4 peneliti melakukan tahapan minimum number *keyword* dimana peneliti menentukan 2 *occurrences* artinya minimum kemunculan pengulangan *keyword* sebanyak 2 kali, dan pada gambar 2.5 merupakan jumlah *keyword*nya.



Gambar 2.6 Pemilihan *keyword*




Gambar 2.7 Jumlah *item* yang sesuai dengan *keyword*

Untuk pemilihan keyword peneliti memilih beberapa *keyword* yang di butuhkan pada penelitiannya seperti pada gambar 2.6, terdapat 18 item yang sesuai dengan *keyword* yang telah di tentukan hasil visualisasinya sebagai berikut:

a. *Network Visualization*

Dalam VOS viewer, opsi *network visualization* menampilkan jejaring antar term saling berhubungan yang digambarkan sebagai berikut:




Gambar 2.8 Network Visualization Vos Viewer

Gambar 2.8 menunjukkan pemetaan kata "rose leaf disease" yang terdiri dari tiga *cluster*, delapan *items*, dan Sembilan *links* yang saling berhubungan berdasarkan kata kunci (*co-word*). Analisis ini dilakukan dengan metode kekuatan asosiasi (*association strength*) menggunakan pengaturan *default*, dengan resolusi pengelompokan sebesar 1.00, set minimum klastering sebanyak 1, dan pemilihan penggabungan kelompok kecil (*small cluster*) dengan rotasi sebesar 90 derajat.

b. *Overlay Visualization*

Pemetaan kata kunci rose leaf disiasa membentuk tiga kluster berdasarkan kata kunci (*co-word*), dan jejak historisnya dapat dilihat dari tahun ke tahun, seperti yang ditunjukkan pada Gambar 2.9. Warna lingkaran di gambar menunjukkan bahwa usia penelitian lebih tua jika warnanya lebih gelap, dan usia penelitian lebih muda jika warnanya lebih terang.

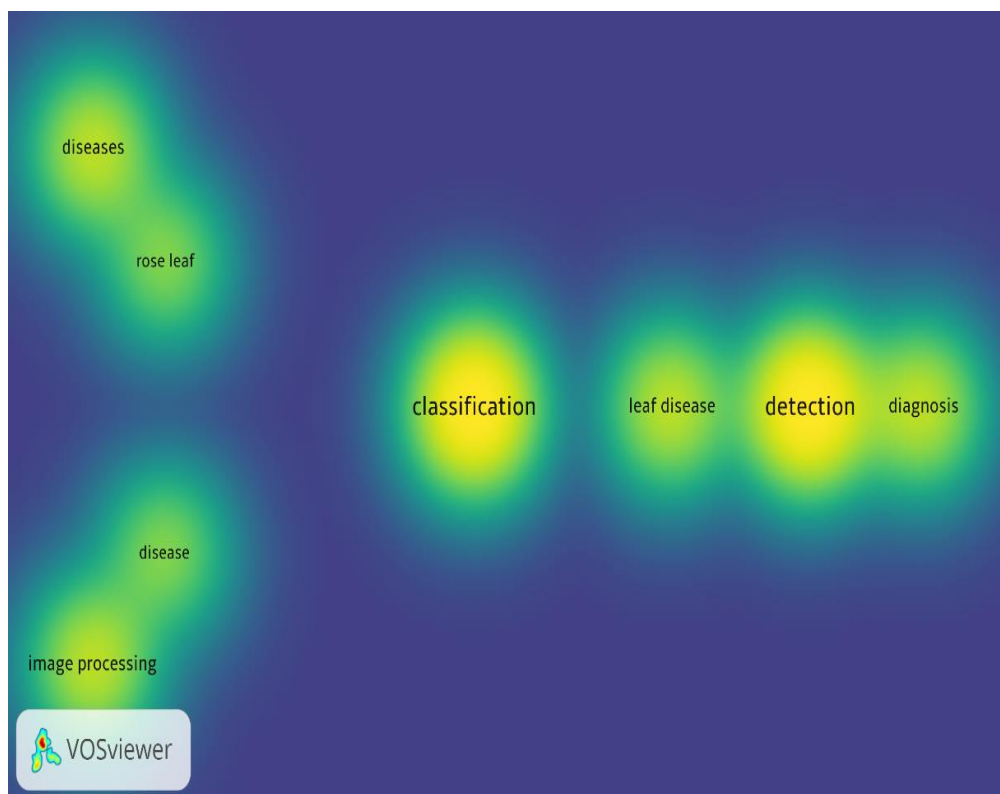
Dalam *VOS Viewer*, jejak historis penelitian dapat dilihat sebagai berikut melalui *opsi overlay visualisasi*:



Gambar 2.9 *Overlay Visualization Vos Viewer*

c. *Density Visualization*

Opsi density visualizatio menunjukkan fokus pada kelompok penelitian.



Gambar 2.10 *Density Visualization Vos Viewer*

Gambar 2.10 menunjukkan bahwa berdasarkan kata kunci (*co-word*), *rose leaf disease* terbentuk menjadi tiga kluster, dan bahwa kata kunci yang lebih terang menunjukkan jumlah penelitian yang telah dilakukan pada kata kunci tersebut. Setelah melakukan screening dari tahun 2021–2023 dan mengeksklusi artikel

ganda menjadi 4.678 artikel, hasil pemetaan bibliometrik dengan kata kunci "rose leaf disease" di database *ScienceDirect*, *ResearchGate*, dan *IEEE* menghasilkan tiga kluster dengan 8 kata kunci yang terkait.

2.3 Literature Review

Salah satu dari banyak metode yang diterapkan dalam kegiatan penelitian adalah peninjauan literatur, yang merupakan langkah kritis dalam tahapan persiapan penelitian. Dalam konteks ini, (Cahyono et al., 2019) mengatakan bahwa ulasan literatur memungkinkan penulis untuk mengidentifikasi teori-teori yang relevan dan memahami metode pengembangan teori. Selain itu, ulasan literatur juga berperan dalam mengidentifikasi perbedaan dan kesamaan di antara teori-teori yang relevan dengan hasil lapangan atau penelitian yang akan dilakukan. Rowley dalam penelitiannya menyatakan bahwa melalui ulasan literatur, peneliti dapat memahami kerangka kerja teoretis yang akan menjadi landasan penelitian. Proses ini melibatkan identifikasi teori-teori yang relevan dan penentuan bagaimana teori-teori tersebut dapat diterapkan dalam konteks penelitian tertentu (Cahyono et al., 2019).

Penting untuk dicatat bahwa, seperti yang dinyatakan oleh Cronin et al.,(2019) meskipun isi dari suatu review literatur dapat berbeda-beda dari satu review ke review lainnya karena konteks dan fokus penelitian yang berbeda, prosedur yang digunakan untuk melakukan review literatur tetaplah sama. Ini mencakup langkah-langkah sistematis dalam pencarian, seleksi, evaluasi, dan sintesis literatur yang relevan. Dengan demikian, ulasan literatur menjadi dasar penting dalam membangun pemahaman yang kuat dan kerangka kerja teoretis yang mendukung penelitian yang dilakukan.

Dengan demikian, peninjauan literatur adalah sebuah proses yang mendalam, berstruktur, dan kritis, yang melibatkan pengumpulan, pemahaman, dan penafsiran literatur ilmiah untuk membangun landasan teoretis yang solid. Kerangka kerja teoretis ini kemudian akan menjadi panduan dalam merancang penelitian dan menganalisis temuan yang diperoleh. Sebagai langkah awal yang penting dalam perjalanan penelitian ilmiah, peninjauan literatur menjembatani kesenjangan pengetahuan, membantu mengidentifikasi fokus penelitian, dan memberikan fondasi yang kokoh bagi hasil penelitian yang mendalam dan bermakna

Dibawah ini merupakan tabel hasil literature review sebagaimana yang bisa dilihat pada tabel 2.1 berikut

Tabel 2.1 Literature Review

No	Identifikasi Artikel	Dataset	Permasalahan	Metode	Tujuan Penelitian	Akurasi	kelebihan	kekurangan
1	A. Rajbongshi, T. Sarker, M. M. Ahamad and M. M. Rahman, "Rose Diseases Recognition using MobileNet," 2020 4th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), Istanbul, Turkey, 2020, pp. 1-7, doi: 10.1109/ISMSIT50672.2020.9254420. https://ieeexplore.ieee.org/abstract/document/9254420	<i>Powdery mildew, black spot, rust, dieback diseases.</i>	Saat ini penyakit tanaman mempengaruhi sektor pertanian kita dengan sangat buruk. Akibatnya, petani menghadapi kerugian besar.	<i>MobileNet</i>	Untuk mengembangkan proses pengobatan dini, deteksi penyakit tanaman mawar yang tepat dan tercepat dapat membantu mengurangi penderitaan ekonomi yang sangat besar.	95,63%	Penggunaan model <i>MobileNet</i> dengan teknik transfer learning telah terbukti efektif dalam mendeteksi penyakit tanaman rose dengan akurasi sekitar 95.63%	Masih ada ruang untuk pengembangan lebih lanjut

Tabel 2.1 Literature Review (Lanjutan)

No	Identifikasi Artikel	Dataset	Permasalahan	Metode	Tujuan Penelitian	Akurasi	kelebihan	kekurangan
2	S. K. Basak, “ <i>Unveiling the Enigma : Advancing Rose Leaf Disease Detection with Transformed Images and Convolutional Neural Networks</i> ,” pp. 1–7. (2023) doi:10.5281/zenodo.8111573 https://zenodo.org/records/8111573	Gambar daun mawar di tiga kategori - Daun Sehat Mawar, Karat Mawar, dan Lalat Gergaji Mawar / Siput Mawar	Mawar, yang terkenal dengan keanggunan dan keindahannya, sangat rentan terhadap berbagai penyakit daun yang dapat memengaruhi kesehatan dan vitalitasnya secara signifikan	CNN	Tujuannya adalah untuk secara akurat mengidentifikasi dan mengklasifikasikan berbagai jenis penyakit daun mawar	95,65%	Teknik augmentasi data untuk mengembangkan model yang dapat mendeteksi penyakit daun mawar	Masih memiliki ruang untuk pengembangan lebih lanjut

Tabel 2.1 Literature Review (Lanjutan)

No	Identifikasi Artikel	Dataset	Permasalahan	Metode	Tujuan Penelitian	Akurasi	kelebihan	kekurangan
3	S. Nuanmeesri, "A Hybrid Deep Learning and Optimized Machine Learning Approach for RoseLeaf Disease Classification," <i>Eng. Technol. Appl. Sci. Res.</i> , vol. 11, no. 5, pp. 7678–7683, 2021, doi: 10.48084/etasr.4455. https://www.researchgate.net/publication/355271558	Gambar daun mawar Dengan dimensi minimal 224 piksel	Masalah hama seperti infeksi serangga sering ditemui bersama dengan patogen yang disebabkan oleh jamur, virus, dan bakteri	VGG16	Mengembangkan <i>model Convolutional Neural Network</i> untuk mengklasifikasikan penyakit pada daun mawar menggunakan teknik deep learning hibrida dengan <i>Support Vector Machine (SVM)</i>	88,33%	Penggunaan SVM sebagai classifier yang menunjukkan hasil yang lebih baik daripada penggunaan fungsi softmax	Penelitian ini hanya fokus pada klasifikasi penyakit pada daun mawar, namun tidak membahas deteksi penyakit pada bagian lain

Tabel 2.1 Literature Review (Lanjutan)

No	Identifikasi Artikel	Dataset	Permasalahan	Metode	Tujuan Penelitian	Akurasi	kelebihan	kekurangan
4	<p>M. Ali-Al-Alvy, G. K. Khan, M. J. Alam, S. Islam, M. Rahman, and M. S. Rahman, "Rose Plant Disease Detection using Deep Learning," <i>7th Int. Conf. Trends Electron. Informatics, ICOEI 2023 - Proc.</i>, no. April, pp. 1244–1249, 2023, doi:10.1109/ICOEI56765.2023.10126031.</p> <p>https://www.researchgate.net/publication/371032045</p>	<p><i>Plant villages.54634 records are in the dataset.</i></p>	<p>Kehilangan dekorasi yang menarik karena tanaman mawarsering sakit.</p> <p>Ekonomi sektor pertanian negara menderita sebagai akibat dari kondisi ini, yang semakin memburuk setiap hari</p>	<p><i>MobileNetV2</i></p>	<p>Untuk mengidentifikasi penyakit pada tanaman mawar</p>	<p>96,11%</p>	<p>Penelitian ini memiliki potensi untuk memberikan kontribusi yang signifikan terhadap sektor pertanian di Bangladesh</p>	<p>Penelitian ini terbatas pada pengumpulan data dari kebun mawar lokal</p>

Tabel 2.1 Literature Review (Lanjutan)

No	Identifikasi Artikel	Dataset	Permasalahan	Metode	Tujuan Penelitian	Akurasi	kelebihan	kekurangan
5	Y. LiuG. Gao “ <i>Identification of multiple leaf diseases using improvedSqueezeNet model</i> ”(2021) DOI:10.11975/j.issn.1002-6819.2021.2.022 https://www.researchgate.net	38 jenis gambar daun (dari 14 tanaman yang berbeda) <i>PlantVillage</i>	Hasil panen sangat dipengaruhi oleh berbagai penyakit tanaman.	<i>SqueezeNet</i>	Identifikasi penyakit daun yang tepat waktu dan akurat sangat diperlukan untuk pengendalian penyakit tanaman	98,13%	Penelitian ini berhasil mengembangkan model deteksi penyakit daun tanaman yang lebih ringan dengan mempertahankan tingkat kinerja yang tinggi	Penelitian ini hanya fokus pada deteksi penyakit daun tanaman.

Tabel 2.1 Literature Review (Lanjutan)

No	Identifikasi Artikel	Dataset	Permasalahan	Metode	Tujuan Penelitian	Akurasi	kelebihan	kekurangan
6	<p>Li, J., Qian, K., Liu, J., Huang, Z., Zhang, Y., Zhao, G., Wang, H., Li, M., Liang, X., Zhou, F., Yu, X., Li, L., Wang, X., Yang, X., & Jiang, Q. (2022). "Identification and diagnosis of meniscus tear by magnetic resonance imaging using a deep learning model"(Li et al., 2022)</p> <p>https://doi.org/10.1016/j.joint.2022.05.006</p>	citra MRI	Intensitas sinyal yang mirip antara degenerasi meniskus dan celah meniskus	<i>Mask R-CNN</i>	Untuk mengembangkan model kecerdasan buatan yang dapat mendiagnosis cedera pada meniskus dengan akurasi tinggi menggunakan citra resonansi magnetik	87,50%	Penelitian ini menggunakan dataset yang luas, dengan hampir dua puluh ribu gambar MRI dari 924 pasien	Penelitian ini tidak membedakan antara jenis cedera pada meniskus.

Tabel 2.1 Literature Review (Lanjutan)

No	Identifikasi Artikel	Dataset	Permasalahan	Metode	Tujuan Penelitian	Akurasi	kelebihan	kekurangan
7	PRATAP, V. K., & KUMAR, D. N. S. (2023). <i>High-precision Multiclass Classification of Chili leaf Disease through Customized EffecientNetB4 from Chili Leaf Images</i> . <i>Smart Agricultural Technology</i> , 5(April), 100295. https://doi.org/10.1016/j.atech.2023.100295	<i>chili leaf image dataset</i>	Ketidakpastian dan keterbatasan tertentu yang memerlukan validasi dan penyempurnaan lebih lanjut	<i>EfficientNetB4</i>	Untuk mengembangkan model deep learning yang dapat secara akurat	82%	Penggunaan teknologi deep learning untuk mengidentifikasi penyakit daun cabai secara akurat dan cepat	Model hanya fokus pada klasifikasi penyakit dan tidak memperhitungkan estimasi keparahan penyakit.

Tabel 2.1 Literature Review (Lanjutan)

No	Identifikasi Artikel	Dataset	Permasalahan	Metode	Tujuan Penelitian	Akurasi	kelebihan	kekurangan
8	Binnar, V., & Sharma, S. (2023). <i>Plant Leaf Diseases Detection Using Deep Learning Algorithms. Lecture Notes in Electrical Engineering</i> , 946(June), 217–228. https://doi.org/10.1007/978-981-19-5868-7_17	<i>Images of diseased apple leaves</i>	Hasil yang berbeda dan terkadang tidak memuaskan ini disebabkan oleh banyaknya kemiripan penyakit	<i>DenseNet</i>	Meningkatkan kinerja model pembelajaran mendalam untuk deteksi penyakit daun apel	97,18%	Penggunaan teknologi deep learning untuk mengidentifikasi penyakit daun cabai secara akurat dan cepat	Model hanya fokus pada klasifikasi penyakit dan tidak memperhitungkan estimasi keparahan penyakit.

Tabel 2.1 Literature Review (Lanjutan)

No	Identifikasi Artikel	Dataset	Permasalahan	Metode	Tujuan Penelitian	Akurasi	kelebihan	kekurangan
9	<i>Multiple disease detection method for greenhouse-cultivated strawberry based on multiscale feature fusion</i> <i>Faster R_CNN</i> , <i>Computers and Electronics in Agriculture</i> , Volume 199, 2022, 107176, ISSN 0168-1699, https://doi.org/10.1016/j.compag.2022.107176 .	<i>The strawberry disease dataset</i>	Bintik-bintik penyakit kecil pada penyakit stroberi dari lingkungan alami	<i>Faster R_CNN</i>	Untuk mengatasi masalah latar belakang yang kompleks dan bintik-bintik penyakit kecil pada gambar penyakit stroberi dari lingkungan alami	92,18%	Penggunaan teknologi deep learning untuk mengidentifikasi penyakit daun cabai secara akurat dan cepat	Model hanya fokus pada klasifikasi penyakit dan tidak memperhitungkan estimasi keparahan penyakit.

Tabel 2.1 Literature Review (Lanjutan)

No	Identifikasi Artikel	Dataset	Permasalahan	Metode	Tujuan Penelitian	Akurasi	kelebihan	kekurangan
10	Arshad, F., Mateen, M., Hayat, S., Wardah, M., Al-Huda, Z., Gu, Y. H., & Al-antari, M. A. (2023). <i>PLDPNet: End-to-end hybrid deep learning framework for potato leaf disease prediction</i> . <i>Alexandria Engineering Journal</i> , 78(August), 406–418. https://doi.org/10.1016/j.aej.2023.07.076	<i>Potato leaf dataset: early blight, late blight, and healthy leaves</i>	Perlunya deteksi penyakit secara dini untuk meminimalkan kerugian petani dan meningkatkan produksi tanaman	<i>VGG19 dan Inception-V3</i>	Menyajikan dan menjelaskan kerangka kerja pembelajaran mendalam hibrida yang disebut PLDPNet untuk memprediksi dan mendeteksi penyakit daun kentang	92,18%	Melakukan studi validasi dengan menggunakan dataset apel dan tomat, dan mencapai akurasi yang mengesankan.	Keterbatasan ketersediaan dataset yang berlabel, yang menyebabkan pembelajaran model ini masih belum komprehensif

Dari table 2.1 terdapat 5 penelitian yang meneliti penyakit pada daun dan daun mawar serta 5 penelitian yang meneliti terkait arsitektur deep learning yang relevan dengan penelitian yang akan di lakukan. Tujuan dari penelitian-penelitian ini adalah untuk mengdiagnosis penyakit pada daun mawar dengan tingkat akurasi yang tinggi.

Penelitian yang di lakukan oleh S. K. Basak, "*Unveiling the Enigma : Advancing Rose Leaf Disease Detection with Transformed Images and Convolutional Neural Networks*" menggunakan CNN untuk mengidentifikasi beberapa penyakit daun, penelitian ini menggunakan model *Convolutional Neural Network* untuk mengidentifikasi berbagai penyakit pada daun tanaman, hasil eksperimen menunjukkan bahwa penggunaan metode ini menghasilkan model CNN dan beban komputasi yang lebih rendah.

Penelitian tersebut bertujuan untuk mendeteksi penyakit daun mawar. Namun, pada penelitian tersebut masih memiliki peluang untuk di kembangkan kembali untuk mendapatkan hasil akurasi yang lebih baik lagi. Model tersebut efektif dalam mengidentifikasi penyakit pada daun mawar, peneliti menyampaikan bahwa model ini dapat dikembangkan lagi.

Dengan demikian, model *Convolutional Neural Network* ini cocok untuk ditingkatkan upaya untuk mendapatkan akurasi yang lebih baik lagi, dengan mengubah parameter untuk mengidentifikasi penyakit pada tanaman secara cepat, akurat, sehingga penulis memutuskan untuk mengadopsi arsitektur ini dalam penelitiannya setelah merujuk beberapa penelitian sebelumnya. Penelitian yang akan dilakukan oleh penulis berjudul "DIAGNOSIS PENYAKIT DAUN MAWAR MENGGUNAKAN PENDEKATAN *DEEP LEARNING*."


2.4 Deep Learning

Menurut Alzubaidi et al., (2022) Metode deep learning yang dikenal sebagai pembelajaran mendalam menggunakan jaringan saraf tiruan yang terdiri dari banyak lapisan untuk mempelajari representasi data yang semakin kompleks (Alzubaidi et al., 2021). Keuntungan deep learning adalah bahwa mesin dapat belajar dengan sendirinya melalui pelatihanabn dataset, membawa terobosan

dalam pemrosesan gambar, dan tidak perlu menentukan fitur secara manual (Li et al., 2022). Menurut Julianto et al., (2023) Salah satu cabang *deep learning* adalah pembelajaran mendalam, yang menggunakan jaringan syaraf tiruan untuk menyelesaikan masalah dengan dataset yang sangat besar yang memanfaatkan berbagai lapisan pengolahan informasi nonlinier untuk klasifikasi, ekstraksi fitur, dan pengenalan pola (Julianto et al., 2023).

2.5 CNN

Convolutional Neural Networks (CNN) adalah teknik pembelajaran mesin yang menggunakan neural network dan umumnya digunakan untuk mengolah gambar (Setyawan & Zaidal, 2014). Gambar diubah menjadi array yang berisi nilai-nilai piksel dengan resolusi tinggi, panjang, dan dimensi yang disebut *channel*. *Channel* ini biasanya terdiri dari 3 lapisan, yang masing-masing mewakili warna merah (Red), hijau (*Green*), dan biru (*Blue*) pada gambar (RGB), atau hanya satu lapisan jika gambar dalam format grayscale (Oktaviari, 2019). Namun, dalam beberapa kasus, jumlah lapisan bisa melebihi 3, bahkan hingga ratusan, untuk merepresentasikan berbagai warna lainnya dengan arsitektur yang lebih kompleks dari RGB. CNN, seperti neural network lainnya, memiliki bobot, bias, dan mekanisme aktivasi, yang memungkinkan CNN menghasilkan output yang tepat (Dzaky, 2021). Model arsitektur CNN dapat dilihat pada gambar 2.11



Gambar 2.11 Model Arsitektur CNN (In, 2018)

Arsitektur CNN umumnya terdiri dari dua bagian besar: *Feature Extraction Layer* dan *Fully Connected Layer*, seperti pada gambar 2.11. Pada *Feature Extraction Layer*, gambar diubah menjadi representasi numerik yang disebut *feature map*, yang memuat informasi penting dari gambar tersebut.

Feature Extraction Layer terdiri dari dua jenis lapisan: *convolution layer* dan *pooling layer*. *Convolution layer* merupakan bagian kunci dari CNN yang membedakannya dari jaringan saraf lainnya. Lapisan ini bertanggung jawab untuk mengekstraksi ciri-ciri atau fitur-fitur dari gambar yang dimasukkan. Proses konvolusi memungkinkan CNN untuk memahami gambar dengan cara yang mirip dengan bagaimana manusia memproses visual. Ini dilakukan dengan menjalankan operasi matematis antara matriks gambar asli dan filter atau *kernel*. Filter ini merupakan matriks kecil yang digunakan untuk memindai seluruh gambar dan mengekstraksi informasi. Kernel biasanya berukuran 3x3 atau 5x5 dan berisi nilai-nilai antara -1 dan 1. Dengan menggunakan konvolusi, CNN dapat mempelajari ciri-ciri seperti tepi, tekstur, atau pola dalam gambar, yang kemudian digunakan untuk proses klasifikasi atau deteksi objek lebih lanjut.

Hasil dari proses konvolusi antara matriks citra dan filter (*kernel*) tersebut disebut *feature map*. *Feature map* adalah representasi *numerik* dari gambar yang menunjukkan di mana ciri-ciri atau fitur-fitur yang penting ditemukan dalam gambar tersebut. Setelah mendapatkan *feature map*, biasanya fungsi aktivasi ReLU (*Rectified Linear Unit*) diterapkan. ReLU berfungsi untuk mengubah nilai negatif dalam *feature map* menjadi nol, sementara nilai positif dibiarkan tidak berubah. Ini membantu dalam meningkatkan kekuatan representasi fitur-fitur yang diambil dari gambar. Dengan menggunakan ReLU, CNN dapat memperoleh *feature map* yang lebih ekspresif dan meningkatkan kemampuan untuk mengekstraksi ciri-ciri penting dari gambar secara lebih efektif. Ini merupakan langkah penting dalam proses pengolahan gambar dengan *Convolutional Neural Network*.

Pooling layer atau proses *Max-Pooling* berfungsi untuk mengurangi ukuran spasial dari *feature map* guna mengurangi jumlah parameter dan perhitungan, terutama saat ukuran citra sangat besar. Setiap *pooling layer* beroperasi secara independen pada setiap *feature map*. *Fully Connected Layer* adalah bagian dimana hasil *feature map* dari proses *Feature Extraction Layer* diubah menjadi vektor menggunakan proses yang disebut *Flatten*. Kemudian, vektor tersebut digunakan sebagai input untuk lapisan-lapisan *fully connected*

layer, mirip dengan jaringan saraf biasa. Fungsi aktivasi seperti *softmax* atau *sigmoid* digunakan untuk menghasilkan *output* klasifikasi, misalnya, mobil, wajah, kucing, atau macan.

Secara singkat, cara kerja metode CNN adalah sebagai berikut: setiap gambar melalui serangkaian proses, dimulai dari penguraian gambar menjadi bagian-bagian kecil, kemudian memasukkan setiap bagian ke dalam jaringan saraf yang lebih kecil. Hasil dari setiap bagian tersebut disimpan dalam *array* baru, lalu dilakukan *downsampling* untuk mengurangi ukuran spasial guna mengurangi kompleksitas dan waktu komputasi, dan terakhir dilakukan prediksi. Kelebihan metode CNN adalah kemampuannya untuk secara otomatis mengekstraksi fitur-fitur penting dari gambar tanpa bantuan manusia. Selain itu, CNN lebih efisien dalam hal memori dan kompleksitas dibandingkan dengan metode jaringan saraf lainnya. Namun, kekurangannya adalah membutuhkan banyak data latih, proses pelatihan yang memakan waktu, dan risiko *overfitting*, yang terjadi ketika model terlalu "menghafal" data latih dan kehilangan kemampuan untuk menggeneralisasi (Oktaviari, 2019).

Dalam penerapan *Convolutional Neural Network* (CNN), terdapat empat *hyperparameter* yang penting untuk ditentukan, yakni:

1. Ukuran *Kernel/Filter*:

Ukuran panjang dan lebar dari filter yang akan digunakan dalam operasi konvolusi. Sebagai contoh, dapat menggunakan ukuran filter 3x3, yang berarti filter tersebut memiliki dimensi 3 piksel panjang dan 3 piksel lebar.

2. Jumlah *Filter*:

Menentukan berapa banyak filter yang akan digunakan pada setiap lapisan konvolusi. Setiap filter akan mendeteksi fitur-fitur tertentu pada gambar. Jumlah filter ini mempengaruhi kompleksitas dan kapasitas model.

3. *Stride*:

Stride mengacu pada seberapa jauh filter akan bergeser setiap kali digunakan pada gambar. Nilai *stride* yang lebih besar dapat mengurangi

ukuran *output* dan komputasi, sementara nilai *stride* yang lebih kecil dapat menyimpan lebih banyak informasi.

4. *Padding*:

Padding adalah teknik penambahan piksel di sekeliling gambar sebelum dilakukan operasi *konvolusi*. Ini membantu mempertahankan informasi di tepi gambar dan mengurangi hilangnya informasi saat operasi konvolusi dilakukan. *Padding* dapat berupa '*valid*' (tanpa *padding*) atau '*same*' (dengan *padding* sehingga *output* memiliki dimensi yang sama dengan *input*) (Trivusi, 2022).

Penentuan nilai-nilai hyperparameter ini sangat penting dalam mendesain arsitektur CNN, dan dapat mempengaruhi performa serta efisiensi model secara keseluruhan.

2.6 Keras

Keras adalah sebuah library atau perpustakaan yang ditulis dalam bahasa pemrograman Python. Tujuan utamanya adalah untuk mempermudah pembuatan dan eksperimen dengan model jaringan saraf. Dengan Keras, Anda dapat dengan mudah membangun model jaringan saraf untuk memecahkan berbagai masalah, seperti pengenalan gambar, teks, atau suara. Salah satu keuntungan besar menggunakan Keras adalah kemampuannya untuk berjalan pada berbagai perangkat keras, termasuk Tensor Processing Unit (TPU) dan Graphic Processing Unit (GPU), yang mempercepat pelatihan model. Selain itu, model yang Anda bangun dengan Keras dapat dengan mudah diekspor ke berbagai format, seperti untuk digunakan di browser web atau di smartphone. Keras dikenal dengan kemudahannya dalam digunakan, yang membuatnya populer di kalangan para peneliti dan pengembang yang ingin cepat membangun dan mengevaluasi model jaringan saraf. Dengan Keras, Anda dapat fokus pada desain model dan eksperimen, tanpa harus terlalu khawatir tentang detail teknis dari implementasinya (Oktaviari, 2019).

2.6 *TensorFlow*

TensorFlow adalah sebuah library perangkat lunak yang bersifat open-source yang digunakan untuk komputasi *dataflow*, yang berarti dapat memproses operasi-operasi matematika pada data dalam bentuk grafik komputasi. Ini membedakannya dari pendekatan pemrograman konvensional yang mengeksekusi operasi satu per satu. Dengan *TensorFlow*, dapat membangun dan melatih model jaringan saraf dengan tingkat abstraksi yang diinginkan (Oktaviari, 2019).

2.7 *Activation Function*

Fungsi aktivasi dalam jaringan saraf adalah seperti saklar di dalam sebuah lampu, ketika saklar diaktifkan, lampu akan menyala; dan ketika saklar dimatikan, lampu akan padam. Demikian pula fungsi aktivasi mengatur apakah neuron dalam jaringan saraf akan aktif atau tidak aktif berdasarkan pada jumlah tertentu dari input yang diterimanya. Dengan kata lain, fungsi aktivasi menentukan apakah neuron tersebut akan mengirimkan sinyal ke neuron lainnya dalam jaringan atau tidak. Dengan bantuan fungsi aktivasi ini, jaringan saraf dapat mempelajari pola-pola yang rumit dari data yang diberikan dan membuat keputusan yang cerdas (Oktaviari, 2019).

2.7.1 *Leaky Rectifier Linear Unit (Leaky ReLU)*

Fungsi aktivasi *Leaky Rectifier Linear Unit (Leaky ReLU)* adalah jenis fungsi aktivasi yang digunakan dalam jaringan saraf.

$$f(x) = \begin{cases} 0.001x & x < 0 \\ x & x \geq 0 \end{cases} \quad (2.1)$$

(Oktaviari, 2019)

Pada persamaan 2.1 fungsi ini bekerja dengan cara yang sederhana: jika nilai input x kurang dari 0, maka nilai outputnya akan menjadi 0.001 dikalikan dengan x . Namun, jika nilai input x lebih besar dari atau sama dengan 0, maka nilai outputnya akan tetap sama dengan x (Oktaviari, 2019).

2.8 *Optimizer RMSProp*

RMSProp adalah varian dari algoritma pembelajaran mesin yang disebut AdaGrad. Ini dirancang untuk lebih efektif dalam situasi di mana saat memiliki

data yang kompleks atau nonkonvensional. RMSProp menggunakan metode yang disebut "moving average eksponensial" untuk menghitung gradien, yang memungkinkan algoritma ini untuk menyesuaikan diri dengan perubahan dalam data dengan lebih baik. Singkatan "RMS" dalam RMSProp berarti "Root Mean Square", yang merujuk pada perhitungan akar kuadrat rata-rata dari gradien. Ini membantu dalam menyesuaikan laju pembelajaran secara adaptif untuk setiap parameter dalam proses pelatihan (Syifa & Dewi, 2022).

2.9 Confusion Matrix

Confusion Matrix ialah tabel yang menguraikan total data pengujian yang diklasifikasikan dengan tepat total data pengujian yang dikelompokkan secara salah (Arfida & Sholeh, 2019). Cara untuk mengukur kinerja model yang dibuat dalam informasi mining *Confusion Matrix*. Matrix kekacauan mengandung prediksi dan data nyata dari sistem pengelompokan (Andi Dipayana et al., 2022). Pengukuran yang digunakan dalam matrix kekacauan termasuk menghitung ketepatan, ketepatan, recall, dan f-measure. Nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) adalah hasil dari matrix kekacauan. Parameter kinerja klasifikasi mengacu pada hasil ketepatan apabila ada selisih tipis antara nilai FP dan FN. (Zhafira et al., 2021).

Table 2.2 Tabel Confusion Matrix (Trivusi, 2022)

		Prediksi		
		Positif	Negatif	Netral
Aktual	Positif	TPos	FPosNeg	FPosNet
	Negatif	FNegPos	Tneg	FNegNet
	Netral	FNetPos	FnetNeg	TNet

Berikut adalah ketentuan dalam menetapkan nilai elemen tersebut:

- TP (*True Positive*) adalah kumpulan data yang kelas aktual dan prediksinya sama.
- *False Negative* (FN) adalah total dari seluruh baris yang ditunjuk kecuali TP yang dicari
- *False Positive* (FP) adalah total dari seluruh baris yang ditunjuk kecuali TP yang dicari dan

- *True Negative* (TN) adalah total dari seluruh baris dan kolom selain TP yang dicari (Trivusi, 2022).

2.9.1 F1 Score

Skor F1 adalah cara untuk mengukur seberapa baik model klasifikasi dalam memprediksi kelas dengan memperhitungkan presisi dan recall. Nilai terbaik yang bisa didapat adalah 1.0, sedangkan yang terburuk adalah 0.0. Secara umum, skor F1 cenderung lebih rendah daripada ukuran akurasi karena mempertimbangkan baik presisi maupun recall dalam perhitungannya. Oleh karena itu, untuk membandingkan model klasifikasi, lebih baik menggunakan rata-rata tertimbang dari skor F1 daripada hanya mengandalkan akurasi secara keseluruhan (Arfida et al., 2023).

Persamaan berikut menunjukkan persamaan akurasi.

$$f1\ score = \frac{2 \times Recall \times Precision}{Recall + Precision} \quad (2.2)$$

(Model, 2023)

2.9.2 Recall

Recall adalah teknik pengujian yang membandingkan jumlah informasi relevan yang diterima sistem dengan total jumlah informasi relevan yang ada dalam koleksi informasi (baik yang diambil atau tidak diambil sistem) (Trivusi, 2022).

Persamaan berikut menunjukkan persamaan recall:

$$Recall = \frac{TP}{TP+FN} \quad (2.3)$$

(Trivusi, 2022)

2.9.3 Precision

Presisi adalah metode pengujian yang membandingkan jumlah informasi relevan yang diterima sistem dengan jumlah total informasi yang diambil sistem, baik yang relevan maupun tidak relevan (Trivusi, 2022).

Persamaan ketepatan ditunjukkan di bawah ini.

$$Recall = \frac{TP}{TP+FP} \quad (2.4)$$

(Trivusi, 2022)

2.10 Daun Mawar

Menurut Rajbongshi et al., (2020) Sebagian besar mawar, anggota keluarga Rosaceae, berasal dari Asia, Amerika Utara, Eropa, dan barat laut Afrika. Sejak lama, orang telah menanam mawar di berbagai negara. Sebaliknya, karena banyak penyakit yang sebelumnya tidak terlihat oleh para petani, produksi mawar potong akhir-akhir ini menurun dan kehilangan kualitas dan nilai ekonominya (Rajbongshi et al., 2020). Menurut Basak (2023) Selama bertahun-tahun, bunga mawar telah dianggap sebagai karena aromanya yang memikat dan keindahannya yang luar biasa. yang dapat membahayakan kesehatan dan keindahannya. Para petani dan penggemar mawar di seluruh dunia menghadapi banyak penyakit daun mawar, seperti siput, karat, dan lalat gergaji (Basak, 2023).