

## BAB II

### TINJAUAN PUSTAKA

#### 2.1 PRISMA

Alat dan panduan yang digunakan untuk melakukan penelitian terhadap sebuah *systematic reviews* dan *meta analysis* (Mohamed et al., 2020). Menurut Mohamed et al., (2020) Prisma diagram adalah Diagram alir menggambarkan aliran informasi melalui fase yang berbeda dari tinjauan sistematis. Ini memetakan jumlah catatan yang diidentifikasi, disertakan dan dikecualikan, dan alasan pengecualian. Templat yang berbeda tersedia tergantung pada jenis ulasan (baru atau diperbarui) dan sumber yang digunakan untuk mengidentifikasi studi. Pembuatan *Systematic Literature Review* (PRISMA) terdiri dari 4 langkah, yaitu :

1. *Identification* (Identifikasi) journal yang akan disertakan dalam meta analisis.
2. *Screening* (Penyaringan), penyaringan atau pemilihan data.
3. *Eligibility* (Kelayakan), menentukan artikel yang akan dijadikan bahan *literature review*.
4. *Included* (Inklusi), yakni penggabungan dan pelaporan hasil.

##### 2.1.1 Identification

*Identification* (Identifikasi) adalah kegiatan yang bertujuan untuk memeriksa dan menganalisa, dalam proses ini penulis mengidentifikasi masalah penelitian (*research problem*) dikarenakan hal tersebut menentukan kualitas suatu penelitian (Mohamed et al., 2020).

##### 2.2.1 Screening

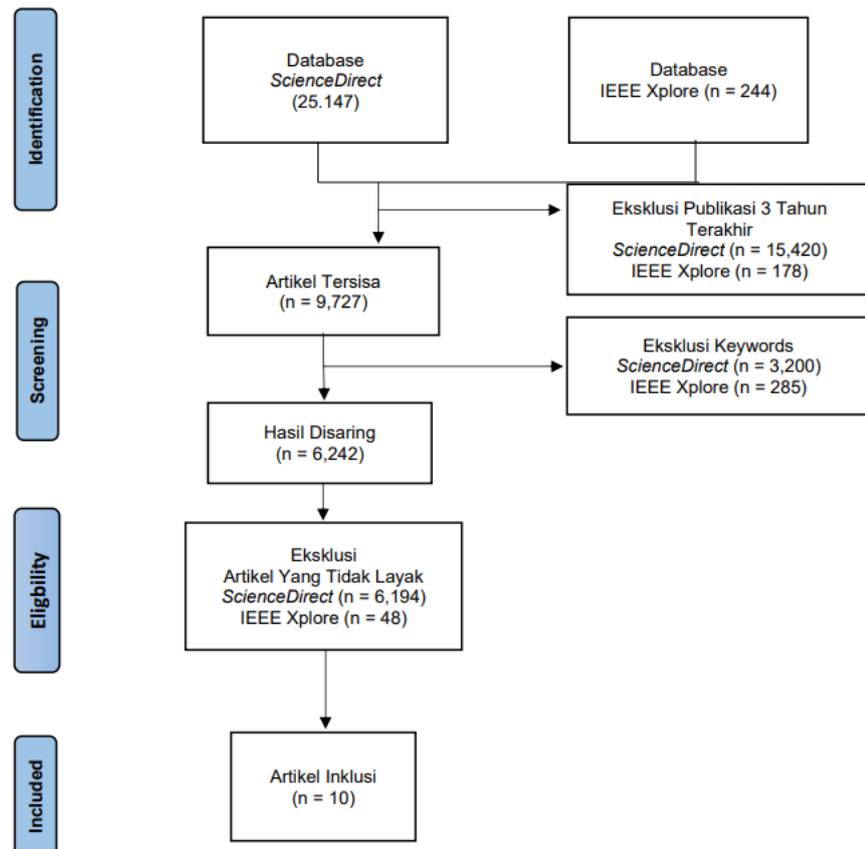
*Screening* (Penyaringan) adalah sebuah proses penyaringan untuk memasukkan atau mengecualikan artikel berdasarkan kriteria yang ditentukan oleh penulis (Mohamed et al., 2020).

### 2.3.1 Eligibility

*Eligibility* adalah tahap penentuan kelayakan artikel semua artikel diperiksa dengan membaca judul, abstrak, hasil dan pembahasan untuk memastikan memenuhi kriteria inklusi dan sejalan dengan tujuan penelitian saat ini (Mohamed et al., 2020).

### 2.4.1 Included

*Included* merupakan tahap terakhir dari PRISMA (*Preferred Reporting Items for Systematic Review And Meta Analyses*) flow diagram, pada tahap ini kriteria inklusi adalah dimana artikel keluar dan memenuhi persyaratan untuk di analisis (Mohamed et al., 2020).



**Gambar 2.1** Prisma Diagram

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

### 1. Identifikasi

Pada saat identifikasi dengan menggunakan topik yang telah disesuaikan, “*Tomato Leaf Disease*” untuk pencarian data, didapatkan jumlah yang berbeda dari setiap database yang digunakan. Dari *ScienceDirect* ditemukan 25,147 artikel, dan IEEE Xplore ditemukan 244 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 terbaru. Artikel terkumpul sebanyak 9,727.
- b. Pengecekan berdasarkan keywords artikel jurnal terkumpul sebanyak 6,242.

### 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 6,242 artikel yang relevan dengan penelitian dan menemukan 10 artikel yang relevan tentang penerapan *Tomato Leaf Disease*.

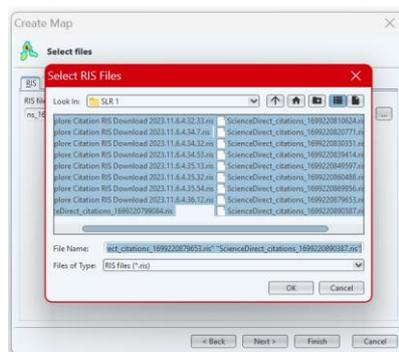
### 4. *Included*

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

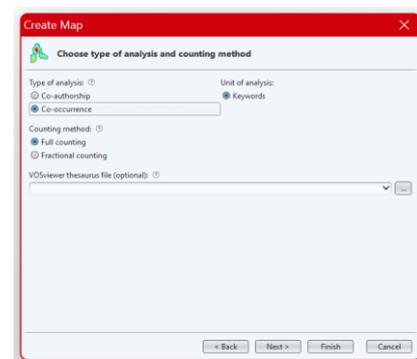
## 2.2 VOSViewer

VOSViewer 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, VOSViewer digunakan untuk analisis bibliometrik, pemetaan topik untuk penelitian terbaru, menemukan referensi yang paling banyak digunakan dalam bidang tertentu, dan lain-lain. VOSViewer dapat membaca dataset dari berbagai situs jurnal internasional seperti *ScienceDirect* dan IEEE Xplore.

Gambar 2.1 menunjukkan tahapan peninjauan sistematis, di mana penulis mengumpulkan 25,391 hasil artikel dari database *ScienceDirect* dan IEEE Xplore. Namun, pengumpulan hasil artikel menjadi 6,242 selama tahap screening, dan 6,242 artikel ini dapat divisualisasikan dengan VOSViewer dengan melakukan tahap pembersihan kembali bagi keywords yang tidak relevan. tahapanya sebagai berikut:

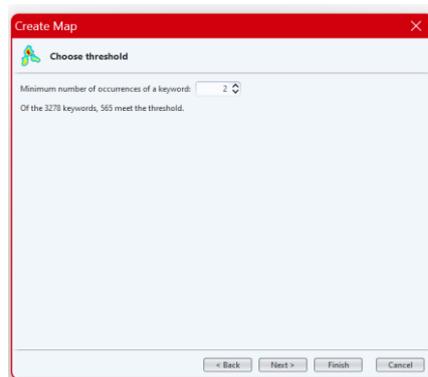


**Gambar 2.2** Input file ris

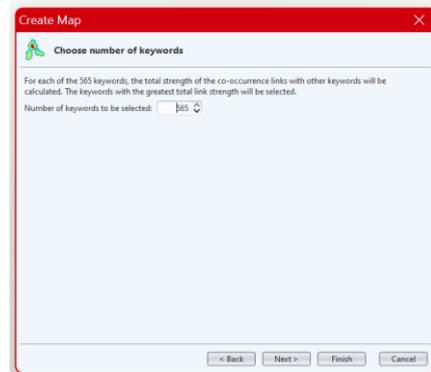


**Gambar 2.3** Memilih type counting

Setelah membuat map baru, input semua file ris dari database *ScienceDirect* dan IEEE Xplore 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 diuji.

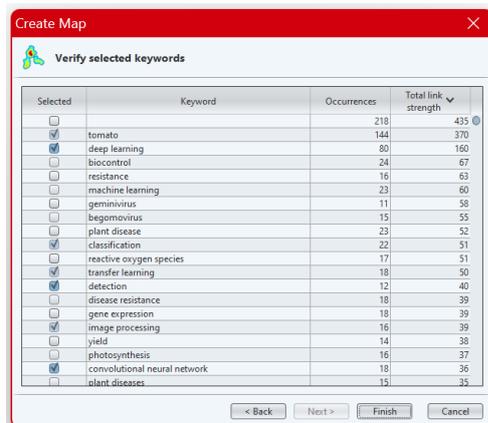


**Gambar 2.4** Menentukan jumlah threshold

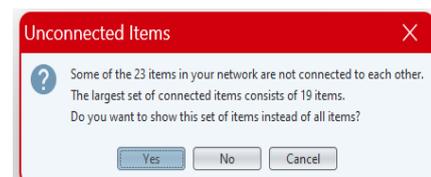


**Gambar 2.5** Jumlah berdasarkan minimum keywords

Tahap berikutnya pada gambar 2.4 peneliti melakukan tahapan minimum number keywords dimana peneliti menentukan 2 occurrences, artinya minimum kemunculan pengulangan keywords sebanyak 2 kali, dan pada gambar 2.5 merupakan jumlah keywordsnya.



**Gambar 2.6** Pemilihan keywords

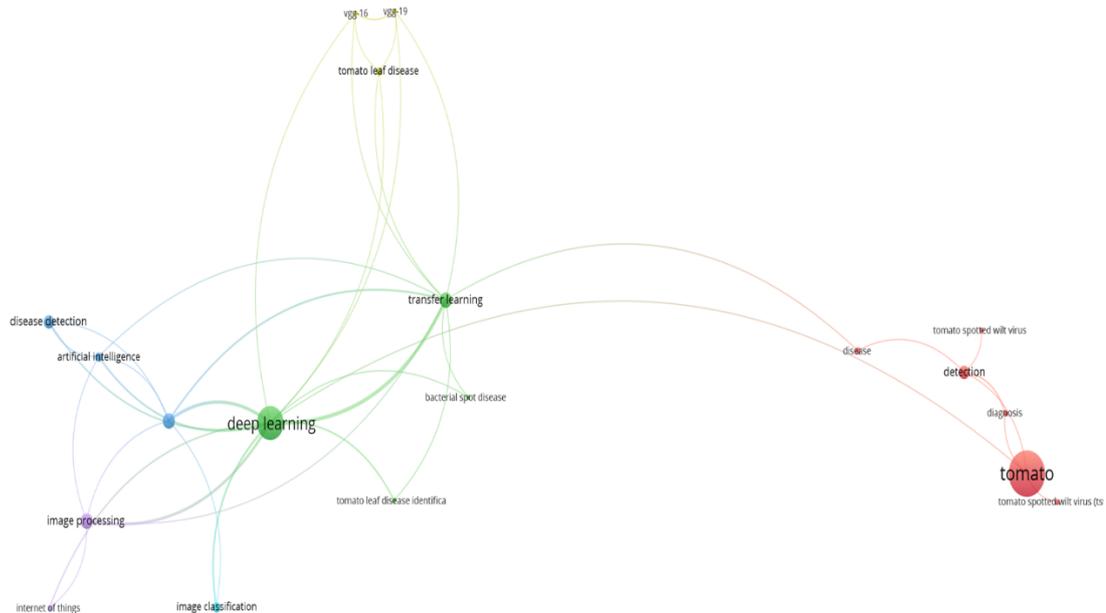


**Gambar 2.7** Jumlah item yang sesuai dengan keywords

Untuk penelitian keywords peneliti memilih beberapa keywords yang dibutuhkan pada penelitiannya seperti pada gambar 2.6, terdapat 23 items sesuai dengan keywords yang telah ditentukan hasil visualisasinya sebagai berikut:

a. *Network Visualization*

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

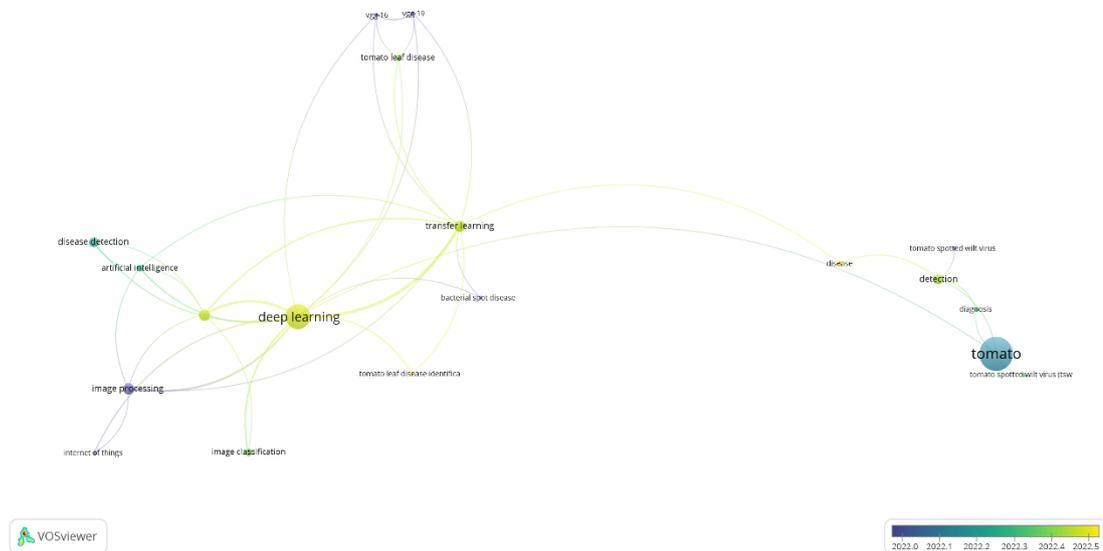


**Gambar 2.8** Network Visualization VOSViewer

Gambar 2.8 menunjukkan bahwa pemetaan kata *Tomato Leaf Disease* terdiri dari 6 kluster yang terdiri dari 19 kata yang saling berhubungan berdasarkan kata kunci (co-word). Pada kluster 1 terdapat 6 items yang berupa *detection*, *diagnosis*, *disease*, *tomato*, *tomato spotted wilt*, *tomato spotted wilt virus*. Kluster 2 terdapat 4 items yang berupa *bacterial spot disease*, *deep learning*, *tomato leaf disease identification*, *transfer learning*. Kluster 3 terdapat 3 items yang berupa *artificial intelligence*, *convolutional neural network*, *disease detection*. Kluster 4 terdapat 3 items yang berupa *tomato leaf disease*, *vgg-16*, *vgg-19*. Kluster 5 terdapat 2 items yang berupa *image processing*, *internet of things*. Kluster 6 terdapat 1 items yang berupa *image classification*.

b. *Overlay Visualization*

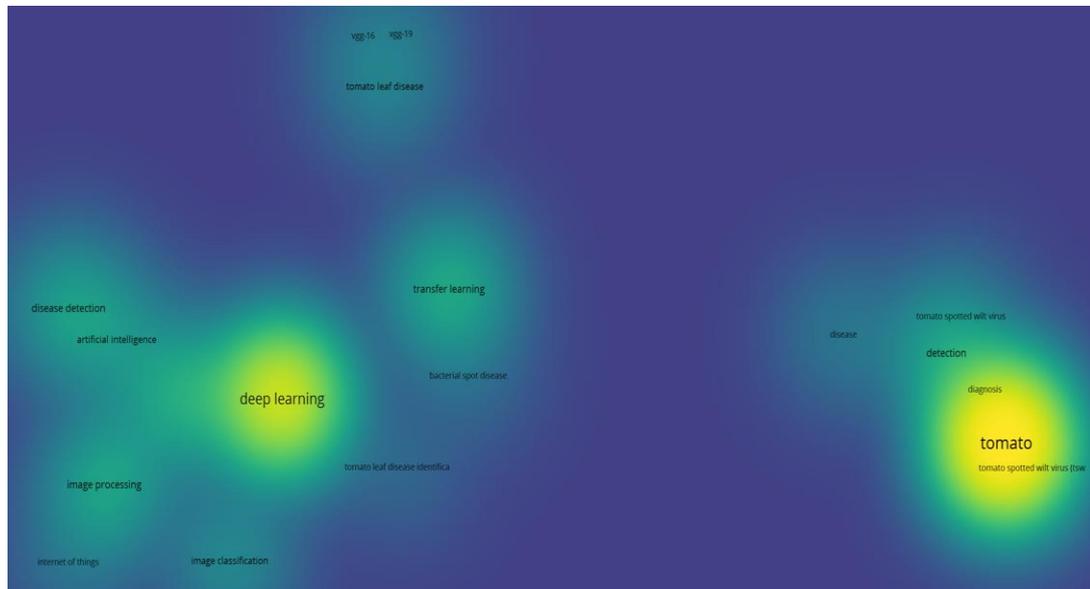
Pemetaan kata kunci *Tomato Leaf Disease* membentuk 6 kluster berdasarkan kata kunci (co-word), dan jejak historisnya dapat dilihat dari tahun ke tahun, seperti yang ditunjukkan pada gambar 2.9. Warna lingkaran di gambar menunjukkan bahwa usia penelitian lebih tua jika warnanya lebih gelap, dan usia penelitian lebih muda jika warnanya lebih terang. Dalam VOSViewer, jejak historis penelitian dapat dilihat sebagai berikut melalui opsi overlay visualisasi:



**Gambar 2.9** *Overlay Visualization VOSViewer*

c. *Density Visualization*

Opsi *density visualization* VOSViewer menunjukkan fokus pada kelompok penelitian.



**Gambar 2.10** *Density Visualization* VOSViewer

Gambar 2.10 menunjukkan bahwa berdasarkan kata kunci (co-word), *Tomato Leaf Disease* terbentuk menjadi 6 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 6,242 artikel, hasil pemetaan bibliometric dengan kata kunci “*Tomato Leaf Disease*” di database *ScienceDirect* dan *IEEE Xplore* menghasilkan 6 kluster dengan 19 kata kunci yang terkait.

### 2.3 *Literature Review*

Salah satu dari banyak metode untuk melakukan kegiatan penelitian adalah meninjau literatur (Cahyono et al., 2019). Rowley menyatakan bahwa ulasan literatur memungkinkan penulis untuk mengidentifikasi teori dengan menggunakan metode pengembangan teori atau metode untuk mengidentifikasi perbedaan di antara teori-teori yang relevan dengan hasil lapangan atau penelitian (Cahyono et al., 2019). Menurut Cronin et al., (2019) Meskipun isi

review literatur terkadang berbeda dari satu review ke review lain, prosedur yang digunakan untuk melakukan review literatur akan sama. Dibawah ini merupakan table hasil *literature review* sebagaimana yang bisa dilihat pada table 2.1 berikut:

Tabel 2.1 Literature Review

No.	Identifikasi Artikel	Dataset	Permasalahan	Metode	Tujuan	Hasil
1.	<p>Peyal, Hasibul Islam &amp; Shahriar, Saleh &amp; Sultana, Abida &amp; Jahan, Ifat &amp; Mondol, Md. (2021). Detection of Tomato Leaf Diseases Using Transfer Learning Architectures: A Comparative Analysis. 1-6.</p> <p><a href="http://dx.doi.org/10.1109/ACMI53878.2021.9528199">http://dx.doi.org/10.1109/ACMI53878.2021.9528199</a></p> <p><a href="https://www.researchgate.net/publication/354456042_Detection_of_Tomato_Leaf_Diseases_Using_Transfer_Learning_Architectures_A_Comparative_Analysis">https://www.researchgate.net/publication/354456042_Detection_of_Tomato_Leaf_Diseases_Using_Transfer_Learning_Architectures_A_Comparative_Analysis</a></p>	Leaf Images	<p>Identifikasi manual penyakit dan hama pada tanaman tomat dengan mata akan memakan waktu yang lama dan seringkali gagal mendeteksi penyakit secara akurat</p>	VGG-19	<p>Mengatasi masalah identifikasi manual penyakit dan hama pada tanaman tomat yang memakan waktu lama dan seringkali gagal mendeteksi penyakit secara akurat</p>	<p>Pendekatan ini meningkatkan akurasi model menjadi 87%</p>

2.	<p>H. Hong, J. Lin and F. Huang, "Tomato Disease Detection and Classification by Deep Learning," 2020 International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE), Fuzhou, China, 2020, pp. 25-29.</p> <p><a href="http://doi.org/10.1109/ICBAIE49996.2020.00012">http://doi.org/10.1109/ICBAIE49996.2020.00012</a></p> <p><a href="https://ieeexplore.ieee.org/abstract/document/9196295">https://ieeexplore.ieee.org/abstract/document/9196295</a></p>	Leaf Images	<p>Dalam keseluruhan siklus pertumbuhan tomat terdapat banyak jenis penyakit dan hama tomat, oleh karena itu deteksi dan diagnosis penyakit tersebut sangat diperlukan</p>	ShuffleNet	<p>Untuk mengurangi ukuran data pelatihan, waktu dan biaya komputasi saat membangun pembelajaran mendalam</p>	<p>Akurasi model ini dapat mencapai 83,68%</p>
3.	<p>A. Hidayatuloh, M. Nursalman and E. Nugraha, "Identification of Tomato Plant Diseases by Leaf Image Using Squeezenet Model," 2018 International Conference on Information Technology Systems and Innovation (ICITSI), Bandung, Indonesia, 2018, pp. 199-204.</p>	Leaf Images	<p>Salah satu permasalahan dalam bidang pertanian adalah</p>	SqueezeNet	<p>Meningkatnya penggunaan ponsel cerdas dan kemajuan di bidang computer</p>	<p>Penelitian ini berhasil mendeteksi penyakit tanaman</p>

	<a href="https://doi.org/10.1109/ICITSI.2018.8696087">https://doi.org/10.1109/ICITSI.2018.8696087</a> <a href="https://ieeexplore.ieee.org/abstract/document/8696087">https://ieeexplore.ieee.org/abstract/document/8696087</a>		<p>mengenai penyakit tanaman. Penyakit tanaman dapat menyebabkan penurunan produksi pertanian</p>		<p>vision melalui pembelajaran mendalam telah memungkinkan untuk menghubungkan ponsel cerdas sebagai alat dalam mendiagnosis penyakit</p>	<p>tomat melalui citra daunnya secara otomatis dengan rata-rata akurasi identifikasi sebesar 86,92%</p>
4.	<p>A. Batool, S. B. Hyder, A. Rahim, N. Waheed, M. A. Asghar and Fawad, "Classification and Identification of Tomato Leaf Disease Using Deep Neural Network," 2020 International Conference on Engineering and Emerging Technologies (ICEET), Lahore, Pakistan, 2020, pp. 1-6.  <a href="https://doi.org/10.1109/ICEET48479.2020.9048207">https://doi.org/10.1109/ICEET48479.2020.9048207</a>  <a href="https://ieeexplore.ieee.org/abstract/document/9048207">https://ieeexplore.ieee.org/abstract/document/9048207</a></p>	Leaf Images	<p>Produktivitas pertanian merupakan sesuatu yang sangat bergantung pada perekonomian.</p>	AlexNet	<p>Untuk menghilangkan semua penyakit secepat mungkin dan menyelamatkan diri dari</p>	<p>Akurasi klasifikasi sebesar 76,1% dicapai dengan menggunakan model AlexNet</p>

			Selain itu, penyakit dan hama tanaman merupakan masalah utama di sektor pertanian		kerusakan tanaman	
5.	Lawrence C. Ngugi, Moataz Abdelwahab, Mohammed Abo-Zahhad, A new approach to learning and recognizing leaf diseases from individual lesions using convolutional neural networks, <i>Information Processing in Agriculture</i> , Volume 10, Issue 1, 2023, Pages 11-27, ISSN 2214-3173. <a href="https://doi.org/10.1016/j.inpa.2021.10.004">https://doi.org/10.1016/j.inpa.2021.10.004</a> <a href="https://www.sciencedirect.com/science/article/pii/S2214317321000822">https://www.sciencedirect.com/science/article/pii/S2214317321000822</a>	PlantVillage	Deteksi dini penyakit tanaman memerlukan suatu sistem monitoring yang dapat mengklasifikasikan tanaman secara akurat dan berjalan secara otomatis	GoogleNet	Untuk menyajikan pendekatan yang lebih baik dalam mendeteksi penyakit daun	GoogleNet mencapai akurasi 84%

			di bidang pertanian			
6.	Tran T-T, Choi J-W, Le T-TH, Kim J-W. A Comparative Study of Deep CNN in Forecasting and Classifying the Macronutrient Deficiencies on Development of Tomato Plant. <i>Applied Sciences</i> . 2019; 9(8):1601. <a href="https://doi.org/10.3390/app9081601">https://doi.org/10.3390/app9081601</a> <a href="https://www.mdpi.com/2076-3417/9/8/1601">https://www.mdpi.com/2076-3417/9/8/1601</a>	Leaf Images	Kekurangan unsur hara merupakan penyebab penyakit serius pada pertumbuhan tanaman, yang mempengaruhi hasil panen	ResNetV2	Untuk memprediksi kekurangan unsur hara secara akurat guna meningkatkan produksi tanaman dan mencegah munculnya patologi tomat akibat kekurangan unsur hara	ResNetV2 mencapai akurasi 79%
7.	D. Devi, N. Prasanna, R. A. S. Prateek Ram, N. Niyaz Mohamed; Tomato leaves disease identification by deep convolution neural network using inception V3. <i>AIP Conf.</i>	PlantVillage	Penyakit daun tomat sebagian besar	InceptionV3	Untuk melakukan deteksi dan	InceptionV3 mencapai

	Proc. 14 December 2023; 2914 (1): 050002. <a href="https://doi.org/10.1063/5.0176545">https://doi.org/10.1063/5.0176545</a> <a href="https://pubs.aip.org/aip/acp/article-abstract/2914/1/050002/2929637/ Tomato-leaves-disease-identification-by-deep?redirectedFrom=fulltext">https://pubs.aip.org/aip/acp/article-abstract/2914/1/050002/2929637/ Tomato-leaves-disease-identification-by-deep?redirectedFrom=fulltext</a>		mempengaruhi proses panen tomat dan berdampak rendah pada sektor pertanian		identifikasi penyakit tanaman	akurasi 78,6%
8.	I. Mubarokah, P. Laksono, Cepy, R. Safitri and I. Idris, "Detection of Begomovirus Disease for Identification of Disease Severity Level in Tomato Leaves Using Convolutional Neural Network (CNN)," 2022 International Symposium on Electronics and Smart Devices (ISESD), Bandung, Indonesia, 2022, pp. 1-6. <a href="https://doi.org/10.1109/ISESD56103.2022.9980675">https://doi.org/10.1109/ISESD56103.2022.9980675</a> <a href="https://ieeexplore.ieee.org/abstract/document/9980675">https://ieeexplore.ieee.org/abstract/document/9980675</a>	PlantVi llage	Tantangan yang sering dihadapi petani tomat adalah maraknya penyakit pada daun tomat yang disebabkan oleh bakteri, virus, dan jamur	EfficientDet D1	Untuk memprediksi penyakit daun tomat berdasarkan citra daun	Efficient Det D1 mencapai akurasi 66,03%

9.	<p>Ji, M., Zhang, K., Wu, Q. et al. Multi-label learning for crop leaf diseases recognition and severity estimation based on convolutional neural networks. <i>Soft Comput</i> 24, 15327–15340 (2020).</p> <p><a href="https://doi.org/10.1007/s00500-020-04866-z">https://doi.org/10.1007/s00500-020-04866-z</a></p> <p><a href="https://link.springer.com/article/10.1007/s00500-020-04866-z">https://link.springer.com/article/10.1007/s00500-020-04866-z</a></p>	Leaf Images	<p>Penyakit tanaman selalu menjadi dilema karena dapat menyebabkan penurunan kualitas dan kuantitas hasil pertanian secara signifikan</p>	NasNet	<p>Untuk mencegah penyakit daun tomat serta kerusakan dan meningkatkan hasil</p>	<p>Mencapai peningkatan akurasi baik yang signifikan sebesar 85,28%</p>
10.	<p>Gudivada, Manikanta Dinesh. An Implementation of Transfer Learning &amp; Deep Learning Techniques to Detect Tomato Leaf Diseases. Diss. Dublin, National College of Ireland, 2020.</p> <p><a href="https://norma.ncirl.ie/4395/1/manikantadineshgudivada.pdf">https://norma.ncirl.ie/4395/1/manikantadineshgudivada.pdf</a></p>	Leaf Images	<p>Dengan pertumbuhan yang tinggi terdapat kerugian yang sangat besar petani karena peningkatan</p>	LeNet	<p>Untuk mendeteksi penyakit daun adalah hal yang utama teknik yang digunakan dalam makalah ini adalah teknik</p>	<p>Model dapat memperoleh akurasi klasifikasi pengujian sebesar 86%</p>

			besar-besaran Penyakit Daun Tomat		Deep Learning dimana data gambar dapat dilatih dan dimodelkan dengan sempurna menggunakan berbagai model Jaringan Neural	
--	--	--	---	--	---	--

Terdapat 10 penelitian yang meneliti penyakit pada daun tomat dengan menggunakan berbagai metode dan teknik, seperti yang ditunjukkan dalam Tabel 2.1 di atas. Tujuan dari penelitian-penelitian ini adalah untuk mengidentifikasi penyakit pada daun tomat dengan tingkat akurasi yang tinggi.

Penelitian yang dilakukan oleh Peyal, Hasibul Islam & Shahriar, Saleh & Sultana, Abida & Jahan, Ifat & Mondol, Md berjudul "" menggunakan VGG-19 untuk mengidentifikasi beberapa penyakit daun, penelitian ini menggunakan model VGG-19 yang telah ditingkatkan untuk mengidentifikasi berbagai penyakit pada daun tanaman, hasil eksperimen menunjukkan bahwa penggunaan metode ini menghasilkan akurasi sebesar 87%.

Penelitian tersebut bertujuan untuk meningkatkan produksi pertanian sebagai respons terhadap peningkatan populasi manusia yang terus meningkat selama beberapa dekade terakhir. Namun, berbagai penyakit tanaman sangat memengaruhi hasil panen. tingkat akurasi yang tinggi ini menunjukkan bahwa model tersebut efektif dalam mengidentifikasi penyakit pada daun tomat, peneliti menyampaikan bahwa model yang ditingkatkan ini dapat diterapkan pada perangkat seluler dan perangkat komputer lainnya yang memiliki sumber daya terbatas untuk membantu mengidentifikasi penyakit tanaman secara real-time dan akurat. Dengan demikian, model VGG-19 ini cocok untuk digunakan dalam situasi di mana ada perlu mengidentifikasi penyakit pada tanaman secara cepat, akurat, dan pada perangkat yang mungkin memiliki keterbatasan sumber daya, sehingga penulis memutuskan untuk mengadopsi arsitektur ini dalam penelitiannya setelah merujuk beberapa penelitian sebelumnya. Penelitian yang akan dilakukan oleh penulis berjudul "DIAGNOSA PENYAKIT DAUN TOMAT MENGGUNAKAN METODE VGG-19"

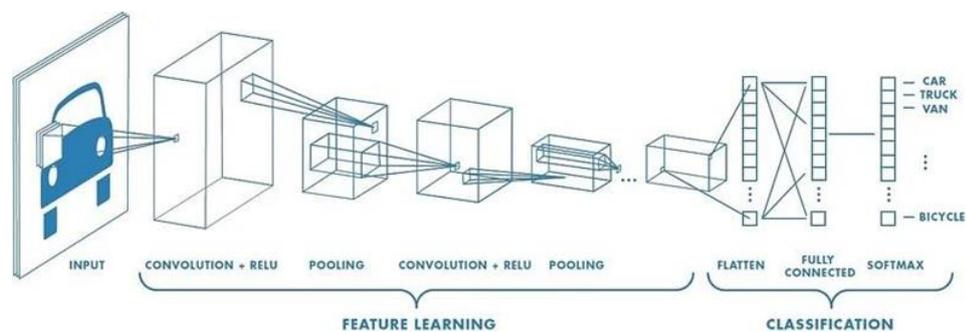
#### **2.4 *Deep Learning***

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 pelatihan 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. Data gambar yang digunakan sebagai input biasanya memiliki ukuran Panjang  $\times$  Lebar  $\times$  channel warna. Ukuran gambar dalam satuan pixel diwakili oleh panjang dan lebar. Namun, channel warna menunjukkan jenis warna apa yang dimiliki gambar. Sebuah gambar *Grayscale*, yang menampilkan hanya satu jenis warna, disebut monokrom, dan gambar normal biasanya terdiri dari tiga channel, dengan setiap channel menunjukkan warna dasar RGB (*Red Green Blue*). 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 (In, 2018)

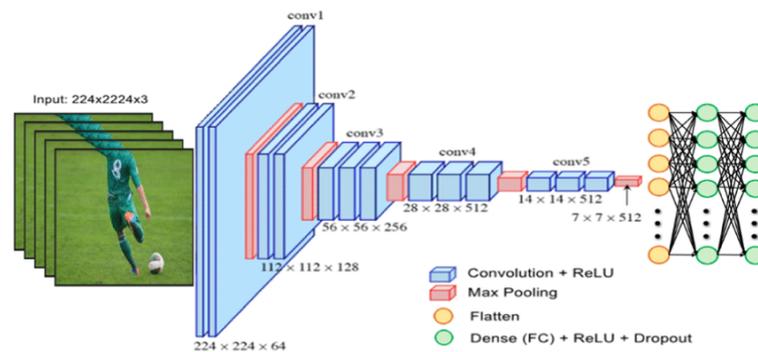


**Gambar 2.11** Model arsitektur CNN (In, 2018)

## 2.6 VGG-19

Jaringan *Deep Learning* dapat diterapkan untuk klasifikasi gambar di banyak bidang berdasarkan ukuran besar kumpulan data dengan sekitar 60 juta parameter dan 650.000 neuron. Dalam praktiknya, arsitektur jaringan dapat memiliki lima lapisan konvolusional dan tiga lapisan yang terhubung sepenuhnya dengan peran yang berbeda. Ada dua lapisan konvolusi pertama (lapisan standar dan pengumpulan maksimal lapisan), lapisan konvolusi ke-3 dan ke-4 (terhubung langsung), lapisan konvolusi terakhir (lapisan max-pooling), dan lapisan keluaran (lapisan softmax). Selain itu, beberapa jaringan memilikinya arsitektur tertentu untuk aplikasi unik. Misalnya, GoogleNet adalah jaringan dengan sekitar 7 juta parameter, 9 modul awal, 4 lapisan konvolusional, 4 pengumpulan maksimal lapisan, 3 lapisan penggabungan rata-rata, 5 lapisan terhubung penuh, dan 3 lapisan softmax. Semua lapisan konvolusional dan dropout menggunakan ReLU (fungsi aktivasi) dengan parameter rasio pengurangan 70% diterapkan pada semua lapisan yang terhubung sepenuhnya.

Selain itu, ResNet serupa ke VGG-19 dan telah diadaptasi berkali-kali untuk menghasilkan ResNet-18, ResNet-34, ResNet-50, ResNet-101, dan ResNet-152. Disini kami menerapkan VGG-19 untuk melatih daun tomat kumpulan data gambar. Pada dasarnya VGG memiliki arsitektur jaringan CNN, dan VGG-19 merupakan salah satu arsitektur berbasis VGG. VGG-19 adalah jaringan saraf pembelajaran mendalam dengan 19 koneksi lapisan, termasuk 16 lapisan konvolusi dan 3 lapisan yang terhubung sepenuhnya. Lapisan konvolusi akan mengekstrak fitur gambar masukan, dan lapisan yang terhubung sepenuhnya akan mengklasifikasikan daun gambar untuk fitur tersebut. Selain itu, lapisan *max-pooling* akan mengurangi fitur dan hindari *overfitting* (Nguyen et al., 2022).



**Gambar 2.11** Arsitektur VGG-19

## 2.7 Confusion Matrix

Menurut Andi Dipayana et al., (2020) *Confusion Matrix* ialah tabel yang menguraikan total data pengujian yang diklasifikasikan dengan tepat total data pengujian yang dikelompokkan secara salah. 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 2.3** 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).

### 2.7.1 Akurasi

Akurasi adalah teknik pengujian yang didasarkan pada tingkat kedekatan antara nilai prediksi dan nilai aktual. Dengan mengetahui jumlah data yang diklasifikasikan dengan benar, kita dapat mengetahui akurasi hasil prediksi (Trivusi, 2022). Persamaan berikut menunjukkan persamaan akurasi.

$$\text{Akurasi} = \frac{TP+TN}{TP+FN+TN} \times 100 \quad (2.1)$$

### 2.7.2 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*:

$$\text{Recall} = \frac{TP}{TP+FN} \quad (2.2)$$

### 2.7.3 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.

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