

BAB I

PENDAHULUAN

1.1. Latar Belakang

Tanaman Cabai telah menjadi salah satu komoditas hortikultura yang memiliki nilai ekonomi penting di Indonesia. Tanaman ini mengandung gizi penting seperti protein, lemak, karbohidrat, kalsium, serta vitamin A dan C, menjadikannya sebagai komoditi yang sangat dibutuhkan oleh masyarakat untuk bahan masakan. Namun, produksi cabai kerap dihadapkan pada tantangan akibat faktor-faktor beragam salah satunya rentan terkena penyakit tanaman. Penyakit yang menyerang tanaman cabai bisa bervariasi. Salah satu penyakit tanaman cabai yaitu penyakit virus kuning dengan memiliki ciri daun berwarna kuning. Penyakit yang tidak terdeteksi dan dibiarkan berkembang akan mengakibatkan kerusakan pada tanaman. Kerusakan tanaman akan mengakibatkan penurunan kualitas atau kuantitas hasil panen. Hal ini dapat memberikan dampak negatif terhadap para petani seperti penurunan hasil panen bisa berdampak pada ekonomi [1].

Banyak petani yang menggantungkan kehidupannya dengan bercocok tanam cabai, namun banyak juga petani yang kurang sigap saat mengatasi tanaman cabai yang terserang penyakit karena belum dapat mengidentifikasi penyakit dan cara pengendaliannya secara cepat dan tepat. Klasifikasi penyakit dan identifikasi penyakit merupakan perhatian penting untuk hasil pangan pertanian yang optimal. Oleh karena itu, menemukan pendekatan

yang cepat, efisien, murah, dan efektif untuk menentukan kejadian penyakit tanaman sangatlah penting guna meningkatkan produktivitas pertanian.

Perkembangan ilmu pengetahuan dan teknologi mampu mengidentifikasi jenis penyakit tanaman cabai tersebut. Pengolahan citra adalah salah satu teknologi yang dapat mengidentifikasi jenis penyakit tanaman cabai, sehingga proses deteksi tidak perlu lagi dilakukan secara manual [2]. Beberapa penelitian telah dilakukan untuk memperoleh pengetahuan mengenai berbagai macam penyakit tanaman cabai. Pengetahuan ini memudahkan perawatan tanaman cabai dengan mengenali ciri-ciri sumber penyakit dan metode pengobatannya [3].

Hadirnya *website* dapat memberikan banyak keuntungan bagi petani cabai dalam mengidentifikasi penyakit. *Website* menyediakan sarana komunikasi yang efektif dan dapat diterapkan di pedesaan sebagai bentuk perkembangan teknologi di sektor terpencil. Dengan adanya *website*, informasi mengenai berbagai penyakit tanaman cabai beserta ciri-ciri dan metode pengobatannya dapat diakses dengan mudah dan cepat. *Website* juga berfungsi sebagai media pemasaran, pendidikan, komunikasi, dan promosi, serta mengenalkan potensi daerah kepada masyarakat luas. Melalui layanan real-time yang disediakan, pengambilan informasi menjadi lebih efisien dibandingkan dengan metode tradisional [4].

Proses klasifikasi ini dilakukan melalui pendekatan *deep learning* dengan menerapkan metode *Convolutional Neural Network (CNN)*. Dalam menangani masalah klasifikasi citra CNN menjadi salah satu algoritma *Deep*

Learning yang paling sering digunakan. Metode CNN terbukti mampu memberikan akurasi lebih tinggi ketika melakukan klasifikasi citra dibandingkan menggunakan metode *machine learning* lainnya [5].

Convolutional Neural Network (CNN) memiliki beberapa arsitektur. Setiap arsitektur memiliki kelebihan dan kekurangannya masing-masing. Model arsitektur memiliki spesifikasi yang berbeda, dimana arsitektur tersebut memiliki proses komputasi yang berbeda serta hasil akurasi yang berbeda [6]. Arsitektur *CNN* yang digunakan akan mempengaruhi hasil akhir dari klasifikasi. Keterbaruan dari penelitian ini yaitu melakukan perbandingan klasifikasi menggunakan 14 arsitektur CNN diantaranya *MobileNet*, *MobileNetV2*, *MobileNetV3 Small*, *MobileNetV3 Large*, *NASNetMobile*, *EfficientNet B0*, *EfficientNetV2B0*, *DenseNet121*, *VGG16*, *Xception*, *InceptionV3*, *ResNet50*, *ResNet50V2* dan *ConvNeXtTiny*.

Pada penelitian ini bertujuan untuk mencari arsitektur *Convolutional Neural Network (CNN)* yang paling cocok digunakan untuk klasifikasi penyakit tanaman cabai berdasarkan citra daun.

1.2. Tujuan dan Manfaat

1.2.1. Tujuan Penelitian

Penelitian ini bertujuan untuk menentukan model *deep learning* berbasis *Convolutional Neural Network (CNN)* yang efektif dan efisien untuk klasifikasi penyakit tanaman cabai berdasarkan citra daun. Selain itu, penelitian ini akan mengevaluasi performa berbagai arsitektur *Convolutional Neural Network (CNN)* dalam hal akurasi, kecepatan,

dan efisiensi. Dengan demikian, diharapkan dapat ditemukan model yang tidak hanya mampu memberikan hasil klasifikasi yang akurat, tetapi juga dapat diterapkan secara praktis dalam sistem berbasis *website* untuk klasifikasi penyakit daun cabai.

1.2.2. Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai berikut:

1. Membantu masyarakat awam terutama yang memiliki tanaman cabai untuk mengidentifikasi jenis penyakit pada daun cabai serta memberikan solusi dan penanganan yang cepat dan tepat.
2. Sebagai bahan referensi dan menambah koleksi karya ilmiah di Perpustakaan Politeknik Harapan Bersama dan sebagai rujukan bagi penulis selanjutnya.

1.3. Tinjauan Pustaka

Tabel GAP di bawah ini disusun untuk memberikan gambaran mengenai penelitian-penelitian sebelumnya yang menggunakan berbagai arsitektur *Convolutional Neural Network (CNN)* dalam klasifikasi citra.

Tabel 1.1 GAP Penelitian

No	Peneliti	Keterangan	Pembeda
1	Ivan Pratama Putra et al. (2022)	Penelitian yang dilakukan menggunakan arsitektur <i>ResNet 50</i> untuk klasifikasi penyakit daun jagung dengan 3 <i>optimizer</i> (Adam, Nadam,	Penelitian ini melibatkan lebih banyak arsitektur CNN dan lima kelas penyakit daun cabai dengan dataset 3000

No	Peneliti	Keterangan	Pembeda
		<p>SGD), 20 <i>epoch</i>, <i>batch size</i> 32, dan <i>learning rate</i> 0,01. Hasilnya menunjukkan bahwa model <i>ResNet 50</i> dengan <i>optimizer Adam</i> mencapai akurasi tertinggi sebesar 98,4%.</p>	<p>gambar. Fokusnya adalah pada perbandingan performa arsitektur CNN, <i>fine-tuning</i>, dan optimasi <i>hyperparameter</i>. Hasil implementasi berupa <i>website</i> yang dapat diakses dari berbagai perangkat, menyediakan informasi tentang penyakit dan langkah pencegahan.</p>
2	Vijayalata Y et al. (2022)	<p>Penelitiannya hanya melakukan komparasi 7 arsitektur CNN dalam klasifikasi penyakit daun singkong tanpa implementasi ke aplikasi pengguna, di mana <i>EfficientNet-B0</i> mencapai akurasi 92,6%.</p>	<p>Penelitian ini memperluas komparasi hingga 14 arsitektur CNN dalam klasifikasi penyakit daun cabai dan diimplementasikan dalam <i>website</i> interaktif yang memungkinkan pengguna mengunggah gambar, menerima hasil klasifikasi, serta informasi terkait</p>

No	Peneliti	Keterangan	Pembeda
			penyakit dan pencegahannya, menjadikannya lebih praktis dan bermanfaat bagi petani serta pengguna umum.
3	Anwar Fuadi dan Aries Suharso (2022)	<p>Penelitian yang dilakukan membandingkan dua arsitektur CNN untuk klasifikasi tiga jenis penyakit kentang menggunakan beberapa skema split data. Hasil penelitian menunjukkan bahwa arsitektur <i>NASNetMobile</i> pada skema <i>split</i> data 90:10 menghasilkan performa terbaik dengan akurasi 90.96%, <i>precision</i> 90.86%, <i>recall</i> 91.11%, dan <i>f1 score</i> 92.93%.</p>	<p>Penelitian ini melibatkan lebih banyak arsitektur CNN dan 5 kelas penyakit daun cabai dengan dataset 3000 gambar. Fokusnya adalah pada perbandingan performa arsitektur CNN, <i>fine-tuning</i>, dan optimasi <i>hyperparameter</i>.</p>

No	Peneliti	Keterangan	Pembeda
4	Ameer Tamoor Khan et al. (2023)	Penelitiannya menggunakan dataset <i>PlantVillage</i> yang berisi gambar daun sehat dan sakit, serta menerapkan arsitektur <i>MobileNetV3-Small</i> dengan <i>fine-tuning</i> pada <i>learning rate</i> (0.0001) dan <i>batch size</i> (64). Model ini diimplementasikan pada perangkat komputasi tepi, seperti ponsel.	Keunggulan penelitian ini terletak pada optimisasi <i>hyperparameter</i> dan implementasinya dalam bentuk <i>website</i> , sehingga dapat diakses dari berbagai perangkat tanpa instalasi khusus, dan menyediakan informasi tambahan mengenai penyebab penyakit dan langkah-langkah pencegahannya.
5	Andi Saputra Sitorus (2023)	Penelitiannya mengidentifikasi penyakit pada tanaman cabai dengan menerapkan metode <i>CNN (Convolutional Neural Network)</i> dan memanfaatkan model <i>VGG16</i> . Tingkat akurasi yang dicapai adalah 92%, dengan tingkat presisi sekitar 92%. Tingkat <i>recall</i>	Penelitian ini membandingkan performa berbagai arsitektur CNN, serta menerapkan <i>fine-tuning</i> dan optimasi <i>hyperparameter</i> seperti <i>learning rate</i> dan <i>batch size</i> untuk meningkatkan performa model serta model diimplementasikan

No	Peneliti	Keterangan	Pembeda
		juga mencapai 92%, sedangkan nilai <i>F1-score</i> mencapai 92%. Namun belum diterapkan pada perangkat apapun.	dalam bentuk <i>website</i> , sehingga dapat diakses dari berbagai perangkat tanpa instalasi khusus, dan menyediakan informasi tambahan mengenai penyebab penyakit dan langkah-langkah pencegahannya.
6	Adhitya Jamalludin Bastari dan Anis Cherid (2023)	Penelitian sebelumnya mengklasifikasikan 4 kelas penyakit tanaman tomat menggunakan arsitektur <i>Inception V3</i> dengan akurasi 99%, diimplementasikan pada perangkat lunak desktop untuk menampilkan hasil klasifikasi jenis penyakit daun.	Penelitian ini melibatkan 14 arsitektur CNN dan 5 kelas penyakit daun cabai, serta melakukan optimasi <i>hyperparameter</i> seperti <i>learning rate</i> dan <i>batch size</i> untuk meningkatkan performa model. Implementasi dilakukan dalam bentuk <i>website</i> yang dapat diakses dari berbagai perangkat tanpa instalasi khusus, serta menyediakan

No	Peneliti	Keterangan	Pembeda
			informasi tambahan mengenai penyebab penyakit dan langkah-langkah penanganannya.
7	M. Farij Amrulloh et al. (2024)	Penelitian sebelumnya menggunakan dataset kecil dengan 4 kelas dan menerapkan arsitektur <i>Xception</i> dengan parameter tetap (<i>batch size</i> 16, <i>epoch</i> 100, <i>dropout</i> 0.2, <i>learning rate</i> 0.00001, <i>optimizer</i> Adam), menghasilkan akurasi training 100% dan validasi 95%, namun terbatas pada pengujian lokal tanpa implementasi perangkat.	Penelitian ini menggunakan dataset lebih besar, menerapkan 14 arsitektur CNN dengan teknik <i>fine-tuning</i> dan optimasi <i>hyperparameter</i> , serta diimplementasikan dalam <i>website</i> yang memungkinkan unggah foto dan memberikan informasi tentang klasifikasi, penyebab penyakit, dan solusinya.
8	Rifqi Raenanda Faqih et al. (2024)	Penelitiannya menerapkan <i>Convolutional Neural Network</i> (CNN) dengan <i>transfer learning</i> menggunakan	Penelitian ini menerapkan <i>fine-tuning</i> dan optimasi <i>hyperparameter</i> , diimplementasikan dalam <i>website</i> interaktif yang

No	Peneliti	Keterangan	Pembeda
		<p><i>MobileNetV3Large</i> untuk deteksi penyakit padi, mencapai akurasi hampir 95% setelah dilatih 200 epoch, namun belum diterapkan pada perangkat apapun.</p>	<p>memungkinkan pengguna mendeteksi penyakit tanaman secara <i>real-time</i> melalui unggahan atau foto, serta memberikan informasi penyebab dan pencegahannya, sehingga menawarkan solusi yang lebih komprehensif.</p>
9	<p>Gunawan Rahmat dan Darmansyah (2024)</p>	<p>Penelitian sebelumnya mengimplementasikan <i>MobileNetV2</i> untuk mendeteksi penyakit tanaman padi, mencapai akurasi 95% pada data latih dan 88% pada data validasi, dengan fokus pada perangkat <i>mobile</i> yang hanya menyediakan fitur unggah gambar dan hasil klasifikasi tanpa informasi penanganan penyakit.</p>	<p>Penelitian ini dikembangkan menjadi <i>website</i> dengan fitur klasifikasi <i>real-time</i> melalui unggah gambar dan pengambilan foto, serta memberikan informasi tentang penyebab penyakit dan cara penanganannya.</p>

No	Peneliti	Keterangan	Pembeda
10	Auliyah Agustina et al. (2024)	<p>Penelitian mengklasifikasikan tiga jenis penyakit padi menggunakan arsitektur <i>DenseNet121</i>. Hasil terbaik dengan akurasi 99,17% dicapai menggunakan augmentasi data (<i>random crop</i>), lebih baik dibanding tanpa augmentasi. Pengujian juga dipengaruhi oleh <i>learning rate</i> dan <i>dropout</i>, namun hanya diuji secara lokal tanpa implementasi perangkat.</p>	<p>Berbeda dengan penelitian ini yang mencakup klasifikasi lima kelas dengan dataset lebih besar (3000 gambar), menggunakan berbagai arsitektur CNN dan <i>fine-tuning hyperparameter</i> untuk hasil yang lebih komprehensif dan akurat. Implementasi <i>website</i> memungkinkan interaksi <i>real-time</i>, memperkuat performa model secara lebih andal.</p>
11	Muhamad Misbahul Munir et al. (2024)	<p>Penelitian yang dilakukan menggunakan dataset kecil dengan 100 gambar daun cabai untuk 3 kelas penyakit, tanpa <i>fine-tuning</i> atau optimasi <i>hyperparameter</i>, dan diuji dengan tiga nilai <i>epoch</i></p>	<p>Penelitian ini menggunakan dataset yang lebih besar, membandingkan performa berbagai arsitektur CNN, serta menerapkan <i>fine-tuning</i> dan optimasi</p>

No	Peneliti	Keterangan	Pembeda
		(10, 20, 30), mencapai akurasi 97,22% dengan <i>MobileNet</i> pada <i>epoch</i> 10.	<i>hyperparameter</i> seperti <i>learning rate</i> dan <i>batch size</i> untuk meningkatkan performa model.
12	Tony O'Halloran et al. (2024)	Penelitian yang dilakukan menguji 6 arsitektur CNN untuk klasifikasi penyakit jagung dengan 2 kelas, <i>learning rate</i> 0.001, dan <i>batch size</i> 16 atau 4, tanpa banyak variasi <i>hyperparameter</i> , dengan hasil terbaik pada <i>EfficientNet V2 B0</i> dengan akurasi 99,99%.	Penelitian ini menguji lebih banyak arsitektur CNN pada klasifikasi penyakit daun cabai dengan 5 kelas, termasuk model modern seperti <i>ConvNeXtTiny</i> dan <i>MobileNetV3</i> , serta melakukan pengoptimalan <i>hyperparameter</i> dengan rentang <i>learning rate</i> dan <i>batch size</i> yang lebih luas.
13	Delvi Hastari et al. (2024)	Penelitian yang dilakukan menggunakan arsitektur <i>ResNet50V2</i> untuk klasifikasi empat kelas penyakit tanaman padi, dengan <i>learning rate</i> tetap (0.0001), <i>batch size</i> 64,	Berbeda dengan penelitian tersebut, penelitian ini lebih komprehensif dengan membandingkan performa berbagai arsitektur CNN pada

No	Peneliti	Keterangan	Pembeda
		dan beberapa <i>optimizer</i> (Adam, SGD, RMSProp). Adam terbukti menjadi <i>optimizer</i> terbaik pada pembagian data 80:20 dengan akurasi 0.9992.	penyakit daun cabai dan mengeksplorasi lebih jauh penyesuaian <i>learning rate</i> serta <i>batch size</i> yang beragam untuk meningkatkan kinerja model.

Beberapa arsitektur CNN digunakan dalam klasifikasi penyakit tanaman, misalnya penelitian yang dilakukan oleh Andi Saputra Sitorus (2023) tentang klasifikasi penyakit pada tanaman cabai dengan menggunakan model *VGG16*. Penelitian ini mencapai akurasi 92%, dengan tingkat presisi, *recall*, dan *F1-score* juga mencapai 92%. Meskipun hasil ini menunjukkan kinerja yang baik, model belum diterapkan pada perangkat apapun, menunjukkan potensi untuk evaluasi lebih lanjut di lingkungan praktis. Penelitian ini relevan karena menunjukkan bagaimana model CNN dapat diterapkan pada klasifikasi penyakit tanaman dan menetapkan dasar untuk membandingkan hasil dengan arsitektur lain [7]. Sementara itu, Muhamad Misbahul Munir et al. (2024) menguji *MobileNet* pada dataset kecil dengan 100 gambar daun cabai, mencapai akurasi 97,22% pada *epoch* 10 tanpa *fine-tuning* atau optimasi *hyperparameter*. Penelitian ini memberikan wawasan tentang efektivitas *MobileNet* pada dataset kecil, meskipun tidak

menggunakan teknik *fine-tuning*. Hasil ini relevan untuk perbandingan karena mengidentifikasi potensi *MobileNet* dalam konteks klasifikasi penyakit tanaman [8]. Adhitya Jamalludin Bastari et al. (2023) menggunakan arsitektur *Inception V3* untuk mengklasifikasikan 4 kelas penyakit pada tanaman tomat, mencapai akurasi 99%. Penelitian ini juga diimplementasikan pada perangkat lunak *desktop*, memberikan hasil yang mengesankan dan relevansi tinggi untuk aplikasi praktis. Hasil ini bermanfaat untuk memahami kinerja *Inception V3* dalam konteks klasifikasi penyakit tanaman dan aplikasinya di dunia nyata [9]. Rifqi Raenanda Faqih et al. (2024) menerapkan *MobileNetV3Large* untuk deteksi penyakit padi dengan akurasi hampir 95% setelah pelatihan 200 epoch, meskipun belum diterapkan pada perangkat. Penelitian ini memberikan wawasan tentang kemampuan *MobileNetV3Large* dalam konteks deteksi penyakit tanaman, yang relevan untuk perbandingan dengan arsitektur CNN lain yang diuji [10]. Gunawan Rahmat dan Darmansyah (2024) mengimplementasikan *MobileNetV2* untuk deteksi penyakit tanaman padi, dengan akurasi 95% pada data latih dan 88% pada data validasi. Fokus pada perangkat *mobile* yang menyediakan fitur unggah gambar menunjukkan relevansi untuk aplikasi praktis, meskipun hasil validasi menunjukkan ruang untuk perbaikan [11]. Penelitian ini menunjukkan pentingnya memilih arsitektur yang sesuai untuk tugas klasifikasi.

Pemilihan *hyperparameter* sangat penting dalam meningkatkan performa model klasifikasi. Ivan Pratama Putra et al. (2022) meneliti

arsitektur *ResNet50* untuk klasifikasi penyakit daun jagung dengan tiga *optimizer* (Adam, Nadam, SGD), menggunakan 20 *epoch*, *batch size* 32, dan *learning rate* 0,01. Hasil menunjukkan bahwa *optimizer* Adam mencapai akurasi tertinggi sebesar 98,4% [12]. Penelitian ini penting karena menyoroti peran *optimizer* dan *fine-tuning* dalam mencapai kinerja terbaik, relevan untuk penelitian yang melibatkan *fine-tuning* dan pemilihan *hyperparameter*.

Ameer Tamoor Khan et al. (2023) menggunakan *MobileNetV3-Small* dengan *fine-tuning* pada *learning rate* (0.0001) dan *batch size* (64) pada dataset *PlantVillage*. Penelitian ini diimplementasikan pada perangkat komputasi tepi, memberikan wawasan tentang penerapan *fine-tuning* dalam praktik [13]. Hasil ini membantu dalam memahami dampak *fine-tuning* terhadap kinerja model dan aplikasi di perangkat komputasi tepi.

M. Farij Amrulloh et al. (2024) menguji arsitektur *Xception* dengan parameter tetap (*batch size* 16, *epoch* 100, *dropout* 0.2, *learning rate* 0.00001, *optimizer* Adam) dan menghasilkan akurasi training 100% dan validasi 95%. Penelitian ini terbatas pada pengujian lokal, namun memberikan informasi penting tentang bagaimana pengaturan parameter tetap mempengaruhi kinerja model dalam konteks dataset kecil [14].

Auliyah Agustina et al. (2024) mengklasifikasikan tiga jenis penyakit padi menggunakan *DenseNet121*, mencapai akurasi 99,17% dengan augmentasi data. Penelitian ini menunjukkan bagaimana augmentasi data dan pemilihan parameter seperti *learning rate* dan *dropout* dapat mempengaruhi kinerja model, meskipun diuji secara lokal tanpa implementasi perangkat [15].

Delvi Hastari et al. (2024) menggunakan

ResNet50V2 untuk klasifikasi empat kelas penyakit tanaman padi dengan *learning rate* tetap (0.0001), *batch size* 64, dan berbagai *optimizer* (Adam, SGD, RMSProp). Hasil menunjukkan bahwa Adam adalah *optimizer* terbaik dengan akurasi 0.9992 pada pembagian data 80:20 [16]. Penelitian ini memberikan wawasan tentang pengaruh berbagai *hyperparameter* yang tepat dalam meningkatkan akurasi model.





Komparasi berbagai arsitektur CNN untuk klasifikasi penyakit tanaman seperti yang dilakukan Vijayalata Y et al. (2022) melakukan komparasi tujuh arsitektur CNN untuk klasifikasi penyakit daun singkong, dengan hasil terbaik pada *EfficientNet-B0* yang mencapai akurasi 92,6%. Penelitian ini memberikan gambaran tentang bagaimana berbagai arsitektur CNN berperforma dalam klasifikasi penyakit tanaman, meskipun tidak diterapkan pada aplikasi pengguna [17]. Anwar Fuadi dan Aries Suharso (2022) membandingkan dua arsitektur CNN untuk klasifikasi tiga jenis penyakit kentang, menunjukkan bahwa *NASNetMobile* dengan skema split data 90:10 menghasilkan performa terbaik dengan akurasi 90,96% [18]. Penelitian ini membantu dalam memahami perbedaan kinerja antara arsitektur CNN dalam konteks klasifikasi penyakit tanaman. Tony O'Halloran et al. (2024) menguji enam arsitektur CNN untuk klasifikasi penyakit jagung, dengan hasil terbaik pada *EfficientNet V2 B0* yang mencapai akurasi 99,99% [19]. Komparasi ini memperlihatkan bahwa arsitektur CNN tertentu dapat lebih cocok untuk tugas klasifikasi tertentu tergantung pada jenis penyakit dan dataset yang digunakan.


Dengan demikian, berbagai arsitektur CNN telah terbukti unggul dalam berbagai aplikasi klasifikasi citra, sehingga mendukung pemilihan arsitektur yang sesuai untuk penelitian ini dalam klasifikasi penyakit daun pada tanaman cabai.

1.4. Data Penelitian

Dalam penyusunan penelitian ini, membutuhkan data dan informasi seputar tanaman cabai. Pengumpulan data dilakukan dengan mengambil dataset yang diperoleh dengan dua cara yaitu observasi ke lahan tanaman cabai dan mengunduh dari database *roboflow*. Untuk contoh data tiap kelas dapat dilihat pada tabel dibawah ini:

Tabel 1.2 Data Penelitian

Kelas	Contoh dataset
Daun sehat	
Daun virus kuning	
Keriting daun	
Bercak daun	

Kelas	Contoh dataset
Bukan daun cabai	

Pada penelitian ini juga terdapat data bahan berupa informasi seputar jenis penyakit yang diperoleh melalui pencarian di *internet* yang kemudian dikumpulkan satu per satu. Informasi yang dikumpulkan yaitu penyebab penyakit, cara pencegahan dan pengendalian yang tepat dan efektif agar dapat membantu petani mengidentifikasi penyakit tanaman lebih dini serta rekomendasi obat apabila tanaman terkena penyakit tersebut.