

Akurasi Citra Image Penyakit Daun Kentang berdasarkan Citra Sehat, Citra *Early Blight*, dan Citra *Late Blight* Menggunakan *Convolutional Neural Network (CNN)*

Rohimah¹, Hariyen Ulfa², Yuliani³, Hafiz Maulana⁴, Luth Fimawahib⁵, Fauzi Erwis⁶

¹²³⁴⁵ Prodi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pasir Pengaraian

⁶ Universitas Rokania, Riau, Indonesia

E-mail : rohimahlubis6@gmail.com¹, hariyenulfanasution@gmail.com², yuli91521@gmail.com³, hafizmaulana133@gmail.com⁴, luthfimmawahib@gmail.com⁵ fauzierwis@gmail.com⁶

Abstrak: Kentang merupakan salah satu produk hasil pertanian yang memiliki kandungan tepung tertinggi keempat setelah jagung, gandum, dan padi. Pengelolaan pertanian kentang menghadapi berbagai permasalahan, salah satunya adalah penyakit pada daun kentang yang dapat menyebabkan hasil produksi yang buruk hingga gagal panen jika tidak ditangani dengan tepat. Dua penyakit yang sering ditemui pada daun kentang adalah *early blight* dan *late blight*, yang masing-masing memiliki gejala serta penanganan berbeda. Proses klasifikasi penyakit yang lambat dapat menyebabkan tambahan biaya untuk perawatan. Penelitian ini memanfaatkan algoritma *deep learning*, yaitu *Convolutional Neural Network (CNN)*, untuk klasifikasi citra daun kentang. Metode *CNN* menggunakan proses konvolusi di mana citra dipecah menjadi gambar-gambar yang lebih kecil dengan konvolusi yang sama. Hasil dari gambar-gambar kecil tersebut kemudian dimasukkan ke dalam array baru yang digunakan untuk prediksi. Data yang digunakan dalam penelitian ini berjumlah 5400 citra, terbagi menjadi tiga kelas: *citra sehat*, *citra early blight*, dan *citra late blight*. Hasil pengujian menunjukkan akurasi tertinggi pada data validasi sebesar 99% dengan waktu komputasi per epoch sekitar 2,5 detik. Dengan demikian, dapat disimpulkan bahwa algoritma *deep learning Convolutional Neural Network (CNN)* mampu melakukan proses klasifikasi penyakit pada citra daun kentang dengan sangat baik.

Kata Kunci: Penyakit Daun Kentang, *Convolutional Neural Network (CNN)*, *Deep Learning*, *Citra Image*

Abstract: Potatoes are an agricultural product that has the fourth highest starch content after corn, wheat and rice. Potato farming management faces various problems, one of which is disease on potato leaves which can cause poor production results and even crop failure if not handled properly. Two diseases that are often found on potato leaves are *early blight* and *late blight*, each of which has different symptoms and treatment. A slow disease classification process can result in additional costs for treatment. This research utilizes a *deep learning* algorithm, namely *Convolutional Neural Network (CNN)*, to classify potato leaf images. The *CNN* method uses a convolution process where the image is split into smaller images with the same convolution. The results of these small images are then entered into a new array that is used for predictions. The data used in this research amounted to 5400 images, divided into three classes: healthy images, *early blight* images, and *late blight* images. The test results show the highest accuracy on validation data of 99% with a computing time per epoch of around 2.5 seconds. Thus, it can be concluded that the *Convolutional Neural Network (CNN) deep learning* algorithm is able to carry out the disease classification process on potato leaf images very well.

Keywords: *Potato Leaf Disease*, *Convolutional Neural Network (CNN)*, *Deep Learning*, *Image classification*.

1. PENDAHULUAN

Kentang merupakan umbi-umbian yang memiliki kandungan karbohidrat [1]. Selain itu kentang juga merupakan salah satu tanaman pangan yang tumbuh subur di dataran tinggi Indonesia, serat dan vitamin C yang baik bagi tubuh terkandung di dalamnya [2]. Dalam membudidayakan suatu tanaman harus memperhatikan beberapa hal demi kelangsungan produksi tanaman berjalan dengan baik, termasuk dalam membudidayakan tanaman kentang [3]. Tetapi pada saat membudidayakan tentu tidak terlepas dari permasalahan tanaman kentang yang terserang penyakit [4]. Petani yang tidak cermat dalam mencermati serangan penyakit pada daun tanaman kentang, penyakit adalah salah satu aspek utama menurunnya kualitas serta kuantitas penciptaan pertanian secara global [5]. Petani sayuran adalah ujung tombak dalam menghasilkan yang baik bagi hasil pertanian sayuran, terutama petani kentang [6]. Petani perlu meningkatkan pengetahuan dalam mencegah, mengidentifikasi, dan menangani tanaman kentang yang belum atau yang sudah terserang penyakit [7]. Penyakit yang paling umum ditemukan pada daun tanaman kentang yaitu busuk daun (*late blight*) dan bercak kering (*early blight*) [8]. Salah satu faktor penyebab terjadinya penyakit busuk daun berkembang yaitu tempat dingin dan lembab [9]. Dengan melakukan identifikasi kedua penyakit pada daun tanaman kentang


ini diharapkan para petani dapat mencegah terjadinya serangan penyakit pada tanaman kentang, sehingga tidak akan terjadi lagi keterhambatan produksi dan pengurangan hasil produksi [10].

Terdapat pada penelitian sebelumnya yang membahas tentang penerapan algoritma Convolutional Neural Network terhadap diagnosis penyakit sawit yang menguji sebanyak 2490 citra menghasilkan nilai akurasi tertinggi sebesar 89% [11] [12]. Penelitian lain dilakukan dengan sedikit modifikasi yaitu dengan penerapan Convolutional Neural Network dengan arsitektur MobileNet pada identifikasi penyakit pada tanaman gambas menghasilkan nilai akurasi sebesar 90% [13] [14]. Penelitian lain pun dilakukan dengan menggunakan algoritma Convolutional Neural Network untuk mengklasifikasi 6 penyakit daun dan 2 daun sehat pada daun apel dan anggur yang menghasilkan nilai akurasi dengan rata-rata 79,25% dan nilai akurasi tertinggi yaitu sebesar 94,767% [15][16]. Selain itu algoritma CNN pun pada penelitian sebelumnya digunakan untuk mendeteksi Covid-19 berdasarkan citra X-Ray yang dibuat berdasarkan model VGG16 melalui transfer learning didapati hasil akurasi yang sangat baik yaitu sebesar 100% dengan menggunakan 24 data [17] [18]. Penelitian yang lain pun dalam mengklasifikasi jerawat berdasarkan jenisnya menggunakan CNN dan menggunakan data train 90% dan data test 10%, dua lapisan konvolusi, lapisan konvolusi pertama 10 filter dan lapisan konvolusi kedua 20 filter, dan menghasilkan nilai akurasi sebesar 91,6% [19][20]. Dari beberapa penelitian tersebut bisa dapat disimpulkan bahwa penggunaan algoritma Convolutional Neural Network dalam identifikasi penyakit pada tanaman cukup baik [21].

Dilihat dari permasalahan tersebut untuk menekan angka kegalalan dalam budidaya kentang teknologi perangkat lunak untuk membantu mendeteksi penyakit lebih dini pada kentang untuk membantu petani dalam budidaya tanaman kentang sangat dibutuhkan. Maka dari itu seiring berkembangnya teknologi, penulis menggunakan bahasa pemrograman python untuk mengidentifikasi penyakit pada daun tanaman kentang dengan menggunakan algoritma Convolutional Neural Network (CNN) [22]. Tujuan dari penelitian ini yaitu identifikasi penyakit daun kentang ke dalam kelas sehat, busuk *daun (late blight)* atau *bercak kering (early blight)* [23] [24].

2. METODOLOGI PENELITIAN

Suatu penelitian membutuhkan langkah-langkah penelitian yang tersusun dengan baik sehingga proses penelitian dapat mencapai tujuan dengan baik. Adapun langkah-langkah penelitian yang dilakukan tercantum pada Gambar 1.



Gambar 1. Metode Penelitian

2.1 Data Collection

Data yang digunakan merupakan data citra yang dapat diakses secara terbuka di situs kaggle dengan total jumlah data sebanyak 5702 citra yang terbagi menjadi 3 kategori, yakni citra sehat, citra penyakit early blight, dan citra penyakit late blight. Jumlah data pada masing-masing kategori nya adalah 1824 citra sehat, 1939 citra early blight, dan 1939 citra late blight.



a. *Early Blight*



b. *Late Blight*



c. *Healthy*

2.2 Data Cleansing

Data Cleansing mengacu pada mengidentifikasi dan memperbaiki kesalahan dalam kumpulan data yang dapat berdampak negatif pada model prediktif [20]. Persebaran data yang tidak merata pada setiap kategori serta banyaknya citra yang kurang jelas dapat memicu terjadinya kesalahan dalam proses klasifikasi citra. Permasalahan tersebut diatasi dengan cara menyeleksi data yang kurang jelas dan menyamakan persebaran data untuk setiap kategori nya. Jumlah persebaran data setelah proses ini adalah 1800 data untuk masing-masing kategori.

2.3 Data Distribution

Pembagian data training dan data validation diperlukan untuk melatih model yang akan digunakan untuk klasifikasi citra. Data akan dibagi menjadi dua, yaitu data training yang berfungsi untuk melatih model dan data validation yang berfungsi untuk memvalidasi model yang telah diuji. Pembagian data dilakukan sebanyak tiga kali dengan skenario yang berbeda. Pada skenario 1, data dibagi menjadi 90:10 untuk data training dan data validasi, pada skenario kedua data dibagi menjadi 80:20 untuk data training dan data validasi, dan pada skenario ketiga, data dibagi menjadi 70:30 untuk data training dan data validasi. Adapun pembagian data dan jumlah citra dari masing-masing skenario dapat dilihat pada Tabel 1.

Tabel 1. Distribusi Data

Skenario	Perbandingan Data	Data Training	Data Validation
1	90:10	4860	540
2	80:20	4320	1080
3	70:30	3780	1620

2.4 Train Model

Penelitian ini dilakukan menggunakan model deep learning dengan arsitektur CNN untuk proses identifikasi penyakit pada citra daun kentang. Model dilatih dengan 25 steps per epoch dan 4 validation steps, setiap citra akan diubah menjadi 150x150 piksel. Model yang digunakan pada penelitian dapat dilihat pada Tabel 2.

Tabel 2. Model Convolutional Neural Network (CNN)

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 148, 148, 16)	448
max_pooling2d (MaxPooling2D)	(None, 74, 74, 16)	0
conv2d_1 (Conv2D)	(None, 72, 72, 32)	4640
max_pooling2d_1 (MaxPooling2D)	(None, 36, 36, 32)	0
conv2d_2 (Conv2D)	(None, 34, 34, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 17, 17, 64)	0
flatten (Flatten)	(None, 18496)	0
dense (Dense)	(None, 512)	9470464
dense_1 (Dense)	(None, 3)	1539
Total params : 9,495,587		
Trainable params : 9,495,587		
Non-trainable params : 0		

3. PEMBAHASAN

Model diuji dengan 3 skenario berbeda untuk melihat hasil terbaik yang bisa didapatkan, masing-masing skenario akan diuji sebanyak 20 epoch dengan 25 steps per epoch dan 4 validation steps dengan train model yang telah dibuat sebelumnya. Citra untuk data training dan data validasi akan diubah menjadi 150x150 piksel untuk mempercepat proses uji coba. Hasil dari ujicoba masing-masing skenario adalah sebagai berikut.


3.1 Hasil Uji Coba Skenario 1

Pada skenario 1, citra dibagi menjadi dua dengan perbandingan 90:10 untuk data training dan data validasi. Jumlah citra yang digunakan adalah 4860 untuk data training, dan 540 untuk data validasi. Citra akan di rescale sebesar 1/255 dari nilai aslinya, rentangan ini berfungsi untuk mempermudah proses belajar dari jaringan syaraf tiruan. Selanjutnya scenario lain adalah ketika citra dirotasi sebesar 20 derajat, dilebarkan sebesar 20% dari ukuran aslinya, ditinggikan sebesar 20% dari ukuran aslinya, dipangkas sebesar 20% dari ukuran aslinya, diperbesar sebanyak 20%, dan jika citra di flip secara horizontal. Nilai piksel yang kosong pada citra akan diisi dengan nilai piksel terdekat. Hasil dari ujicoba pada skenario 1 menunjukkan akurasi tertinggi yaitu 91% untuk data training dan 99% untuk data validation. Proses uji coba skenario 1 dapat dilihat pada Gambar 2. dan grafik akurasi dapat dilihat pada Gambar 3.

```

Epoch 1/20
25/25 - 251s - loss: 2.1346 - accuracy: 0.3775 - val_loss: 0.9805 - val_accuracy: 0.5547 - 251s/epoch - 10s/step
Epoch 2/20
25/25 - 205s - loss: 0.9550 - accuracy: 0.5013 - val_loss: 1.0117 - val_accuracy: 0.4922 - 205s/epoch - 8s/step
Epoch 3/20
25/25 - 156s - loss: 0.9516 - accuracy: 0.5375 - val_loss: 0.8170 - val_accuracy: 0.6406 - 156s/epoch - 6s/step
Epoch 4/20
25/25 - 130s - loss: 0.8842 - accuracy: 0.5838 - val_loss: 0.7080 - val_accuracy: 0.6797 - 130s/epoch - 5s/step
Epoch 5/20
25/25 - 116s - loss: 0.8136 - accuracy: 0.6350 - val_loss: 0.7145 - val_accuracy: 0.6094 - 116s/epoch - 5s/step
Epoch 6/20
25/25 - 100s - loss: 0.6911 - accuracy: 0.6975 - val_loss: 0.6257 - val_accuracy: 0.6875 - 100s/epoch - 4s/step
Epoch 7/20
25/25 - 78s - loss: 0.6282 - accuracy: 0.7013 - val_loss: 0.7040 - val_accuracy: 0.6406 - 78s/epoch - 3s/step
Epoch 8/20
25/25 - 72s - loss: 0.6036 - accuracy: 0.7550 - val_loss: 2.0261 - val_accuracy: 0.5000 - 72s/epoch - 3s/step
Epoch 9/20
25/25 - 62s - loss: 0.6241 - accuracy: 0.7487 - val_loss: 0.5426 - val_accuracy: 0.7344 - 62s/epoch - 2s/step
Epoch 10/20
25/25 - 51s - loss: 0.5103 - accuracy: 0.7975 - val_loss: 0.4292 - val_accuracy: 0.8594 - 51s/epoch - 2s/step
Epoch 11/20
25/25 - 43s - loss: 0.4856 - accuracy: 0.8125 - val_loss: 0.5176 - val_accuracy: 0.7969 - 43s/epoch - 2s/step
Epoch 12/20
25/25 - 42s - loss: 0.4821 - accuracy: 0.8241 - val_loss: 0.2896 - val_accuracy: 0.8984 - 42s/epoch - 2s/step
Epoch 13/20
25/25 - 40s - loss: 0.4082 - accuracy: 0.8438 - val_loss: 0.3202 - val_accuracy: 0.9062 - 40s/epoch - 2s/step
Epoch 14/20
25/25 - 35s - loss: 0.3807 - accuracy: 0.8675 - val_loss: 0.4743 - val_accuracy: 0.7969 - 35s/epoch - 1s/step
Epoch 15/20
25/25 - 28s - loss: 0.3691 - accuracy: 0.8525 - val_loss: 0.2717 - val_accuracy: 0.9141 - 28s/epoch - 1s/step
Epoch 16/20
25/25 - 29s - loss: 0.5065 - accuracy: 0.8825 - val_loss: 0.1201 - val_accuracy: 0.9922 - 29s/epoch - 1s/step
Epoch 17/20
25/25 - 29s - loss: 0.2581 - accuracy: 0.9112 - val_loss: 0.2392 - val_accuracy: 0.8984 - 29s/epoch - 1s/step
Epoch 18/20
25/25 - 28s - loss: 0.2695 - accuracy: 0.9008 - val_loss: 0.2806 - val_accuracy: 0.8672 - 28s/epoch - 1s/step
Epoch 19/20
25/25 - 26s - loss: 0.2985 - accuracy: 0.8850 - val_loss: 0.3449 - val_accuracy: 0.8359 - 26s/epoch - 1s/step
Epoch 20/20
25/25 - 27s - loss: 0.2275 - accuracy: 0.9158 - val_loss: 0.2232 - val_accuracy: 0.9062 - 27s/epoch - 1s/step
    
```

Gambar 2. Hasil uji coba skenario 1



Gambar 3. Grafik hasil uji coba skenario 1

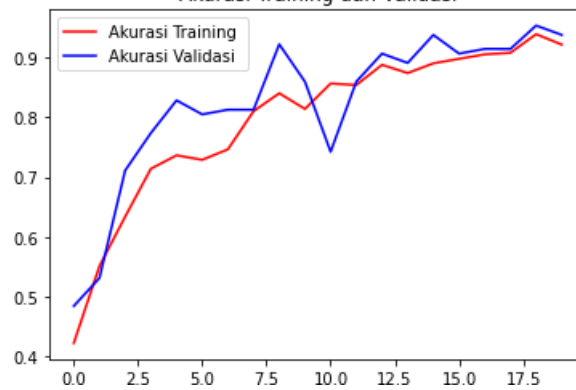
3.2 Hasil Uji Coba Skenario 2

Pada skenario 2, citra dibagi menjadi dua dengan perbandingan 80:20 untuk data training dan data validasi. Jumlah citra yang digunakan adalah 4320 untuk data training, dan 1080 untuk data validasi. Citra akan di *rescale* sebesar 1/255 dari nilai aslinya, rentangan ini berfungsi untuk mempermudah proses belajar dari jaringan syaraf tiruan. Selanjutnya skenario lain adalah ketika citra dirotasi sebesar 20 derajat, dilebarkan sebesar 20% dari ukuran aslinya, ditinggikan sebesar 20% dari ukuran aslinya, dipangkas sebesar 20% dari ukuran aslinya, diperbesar sebanyak 20%, dan jika citra di *flip* secara horizontal. Nilai piksel yang kosong pada citra akan diisi dengan nilai piksel terdekat. Uji coba pada skenario 2 menunjukkan hasil akurasi tertinggi yaitu 93% untuk data *training* dan 95% untuk data *validation*. Proses uji coba dapat dilihat pada Gambar 4 dan grafik akurasi dapat dilihat pada Gambar 5.

```

Epoch 1/20
25/25 - 28s - loss: 1.3752 - accuracy: 0.4225 - val_loss: 0.9815 - val_accuracy: 0.4844 - 28s/epoch - 1s/step
Epoch 2/20
25/25 - 26s - loss: 0.9011 - accuracy: 0.5512 - val_loss: 0.9012 - val_accuracy: 0.5312 - 26s/epoch - 1s/step
Epoch 3/20
25/25 - 25s - loss: 0.8275 - accuracy: 0.6338 - val_loss: 0.7421 - val_accuracy: 0.7109 - 25s/epoch - 1s/step
Epoch 4/20
25/25 - 26s - loss: 0.6788 - accuracy: 0.7138 - val_loss: 0.5342 - val_accuracy: 0.7734 - 26s/epoch - 1s/step
Epoch 5/20
25/25 - 26s - loss: 0.6464 - accuracy: 0.7362 - val_loss: 0.4965 - val_accuracy: 0.8281 - 26s/epoch - 1s/step
Epoch 6/20
25/25 - 25s - loss: 0.6397 - accuracy: 0.7287 - val_loss: 0.5329 - val_accuracy: 0.8047 - 25s/epoch - 999ms/step
Epoch 7/20
25/25 - 25s - loss: 0.5729 - accuracy: 0.7462 - val_loss: 0.4891 - val_accuracy: 0.8125 - 25s/epoch - 1s/step
Epoch 8/20
25/25 - 25s - loss: 0.4889 - accuracy: 0.8100 - val_loss: 0.5754 - val_accuracy: 0.8125 - 25s/epoch - 1s/step
Epoch 9/20
25/25 - 25s - loss: 0.4247 - accuracy: 0.8400 - val_loss: 0.3022 - val_accuracy: 0.9219 - 25s/epoch - 992ms/step
Epoch 10/20
25/25 - 25s - loss: 0.4784 - accuracy: 0.8138 - val_loss: 0.3582 - val_accuracy: 0.8594 - 25s/epoch - 996ms/step
Epoch 11/20
25/25 - 25s - loss: 0.3408 - accuracy: 0.8562 - val_loss: 0.5688 - val_accuracy: 0.7422 - 25s/epoch - 982ms/step
Epoch 12/20
25/25 - 24s - loss: 0.3819 - accuracy: 0.8537 - val_loss: 0.3796 - val_accuracy: 0.8594 - 24s/epoch - 973ms/step
Epoch 13/20
25/25 - 25s - loss: 0.3158 - accuracy: 0.8875 - val_loss: 0.2368 - val_accuracy: 0.9062 - 25s/epoch - 982ms/step
Epoch 14/20
25/25 - 24s - loss: 0.3827 - accuracy: 0.8737 - val_loss: 0.2655 - val_accuracy: 0.8906 - 24s/epoch - 974ms/step
Epoch 15/20
25/25 - 24s - loss: 0.2709 - accuracy: 0.8900 - val_loss: 0.1447 - val_accuracy: 0.9375 - 24s/epoch - 970ms/step
Epoch 16/20
25/25 - 24s - loss: 0.3492 - accuracy: 0.8975 - val_loss: 0.1969 - val_accuracy: 0.9062 - 24s/epoch - 974ms/step
Epoch 17/20
25/25 - 24s - loss: 0.2395 - accuracy: 0.9050 - val_loss: 0.1840 - val_accuracy: 0.9141 - 24s/epoch - 970ms/step
Epoch 18/20
25/25 - 24s - loss: 0.2676 - accuracy: 0.9075 - val_loss: 0.2200 - val_accuracy: 0.9141 - 24s/epoch - 972ms/step
Epoch 19/20
25/25 - 24s - loss: 0.1824 - accuracy: 0.9388 - val_loss: 0.1876 - val_accuracy: 0.9531 - 24s/epoch - 970ms/step
Epoch 20/20
25/25 - 24s - loss: 0.2077 - accuracy: 0.9212 - val_loss: 0.1448 - val_accuracy: 0.9375 - 24s/epoch - 975ms/step
    
```

Gambar 4. Hasil uji coba skenario 2
 Akurasi Training dan Validasi




Gambar 5. Grafik hasil uji coba skenario 2

1. Hasil Uji Coba Skenario 3

Pada skenario 3, citra dibagi menjadi dua dengan perbandingan 70:30 untuk data training dan data validasi. Jumlah citra yang digunakan adalah 3780 untuk data training, dan 1620 untuk data validasi. Citra akan di *rescale* sebesar 1/255 dari nilai aslinya, rentangan ini berfungsi untuk mempermudah proses belajar dari jaringan syaraf tiruan. Selanjutnya skenario lain adalah ketikacitra dirotasi sebesar 20 derajat, dilebarkan sebesar 20% dari ukuran aslinya, ditinggikan sebesar 20% dari ukuran aslinya, dipangkas sebesar 20% dari ukuran aslinya, diperbesar sebanyak 20%, dan jika citra di *flip* secara horizontal. Nilai piksel yang kosong pada citra akan diisi dengan nilai piksel terdekat. Uji coba pada skenario 1 menunjukkan hasil akurasi tertinggi yaitu 90% untuk data *training* dan 94% untuk data *validation*. Proses uji coba dapat dilihat pada Gambar 6 dan grafik akurasi dapat dilihat pada Gambar 7.

Choose Files PotatoEarlyBlight3.JPG
 • **PotatoEarlyBlight3.JPG**(image/jpeg) - 17949 bytes, last modified: 10/12/2019 - 100% done
 Saving PotatoEarlyBlight3.JPG to PotatoEarlyBlight3.JPG
 PotatoEarlyBlight3.JPG
 Citra yang dipilih adalah citra dengan penyakit early blight



Gambar 6. Hasil uji coba skenario 3

```

Epoch 1/20
25/25 - 26s - loss: 1.9919 - accuracy: 0.4375 - val_loss: 0.9055 - val_accuracy: 0.6094 - 26s/epoch - 1s/step
Epoch 2/20
25/25 - 25s - loss: 0.8598 - accuracy: 0.6075 - val_loss: 0.8614 - val_accuracy: 0.6016 - 25s/epoch - 990ms/step
Epoch 3/20
25/25 - 24s - loss: 0.7831 - accuracy: 0.6464 - val_loss: 0.6398 - val_accuracy: 0.7422 - 24s/epoch - 961ms/step
Epoch 4/20
25/25 - 24s - loss: 0.8133 - accuracy: 0.6412 - val_loss: 0.6756 - val_accuracy: 0.6406 - 24s/epoch - 960ms/step
Epoch 5/20
25/25 - 25s - loss: 0.6751 - accuracy: 0.6988 - val_loss: 0.7117 - val_accuracy: 0.7031 - 25s/epoch - 987ms/step
Epoch 6/20
25/25 - 25s - loss: 0.7055 - accuracy: 0.7125 - val_loss: 0.5649 - val_accuracy: 0.7891 - 25s/epoch - 982ms/step
Epoch 7/20
25/25 - 25s - loss: 0.6210 - accuracy: 0.7287 - val_loss: 0.5457 - val_accuracy: 0.7891 - 25s/epoch - 980ms/step
Epoch 8/20
25/25 - 24s - loss: 0.5819 - accuracy: 0.7538 - val_loss: 0.5062 - val_accuracy: 0.8047 - 24s/epoch - 979ms/step
Epoch 9/20
25/25 - 24s - loss: 0.5709 - accuracy: 0.7650 - val_loss: 0.4483 - val_accuracy: 0.8203 - 24s/epoch - 977ms/step
Epoch 10/20
25/25 - 24s - loss: 0.5164 - accuracy: 0.7912 - val_loss: 0.3649 - val_accuracy: 0.8438 - 24s/epoch - 974ms/step
Epoch 11/20
25/25 - 24s - loss: 0.5126 - accuracy: 0.8018 - val_loss: 0.5739 - val_accuracy: 0.7031 - 24s/epoch - 949ms/step
Epoch 12/20
25/25 - 24s - loss: 0.4544 - accuracy: 0.8037 - val_loss: 0.6634 - val_accuracy: 0.6484 - 24s/epoch - 966ms/step
Epoch 13/20
25/25 - 24s - loss: 0.5458 - accuracy: 0.7966 - val_loss: 0.4063 - val_accuracy: 0.8125 - 24s/epoch - 940ms/step
Epoch 14/20
25/25 - 24s - loss: 0.4305 - accuracy: 0.8487 - val_loss: 0.4587 - val_accuracy: 0.7734 - 24s/epoch - 965ms/step
Epoch 15/20
25/25 - 23s - loss: 0.3740 - accuracy: 0.8394 - val_loss: 0.5140 - val_accuracy: 0.7578 - 23s/epoch - 939ms/step
Epoch 16/20
25/25 - 24s - loss: 0.5668 - accuracy: 0.8075 - val_loss: 0.3468 - val_accuracy: 0.8516 - 24s/epoch - 964ms/step
Epoch 17/20
25/25 - 24s - loss: 0.2800 - accuracy: 0.8963 - val_loss: 0.4099 - val_accuracy: 0.8516 - 24s/epoch - 966ms/step
Epoch 18/20
25/25 - 24s - loss: 0.3424 - accuracy: 0.8666 - val_loss: 0.5834 - val_accuracy: 0.7734 - 24s/epoch - 941ms/step
Epoch 19/20
25/25 - 24s - loss: 0.2757 - accuracy: 0.8913 - val_loss: 0.2473 - val_accuracy: 0.8984 - 24s/epoch - 960ms/step
Epoch 20/20
25/25 - 23s - loss: 0.2528 - accuracy: 0.9054 - val_loss: 0.1902 - val_accuracy: 0.9453 - 23s/epoch - 934ms/step

```



Gambar 7. Grafik hasil uji coba skenario 3

Metode convolutional neural network (CNN) memanfaatkan *layer* konvolusi dengan menggerakkan sebuah filter berukuran tertentu kedalam sebuah citra. Kemudian CNN akan memecah citra menjadi beberapa bagian kecil dengan *layer* konvolusi yang sama. Nilai dari konvolusi tersebut kemudian dimasukkan kedalam sebuah array baru, dimana array tersebut akan digunakan oleh jaringan syaraf untuk mengklasifikasi sebuah citra. Hasil klasifikasi citra daun kentang berdasarkan hasil dari *train model*

5. KESIMPULAN

Metode Convolutional Neural Network (CNN) terbukti efektif dalam mengidentifikasi penyakit pada daun kentang, khususnya early blight dan late blight. Hasil uji coba pada tiga skenario menunjukkan bahwa akurasi tertinggi pada data validasi mencapai 99% dengan akurasi pada data pelatihan sebesar 91% dalam skenario pertama, 95% dalam skenario kedua, dan 94% dalam skenario ketiga. Temuan ini menunjukkan bahwa CNN mampu melakukan klasifikasi citra penyakit pada daun kentang dengan sangat baik dan konsisten. Dengan demikian, penerapan teknologi ini dapat membantu petani dalam mendeteksi penyakit daun kentang secara lebih cepat dan akurat, yang pada akhirnya dapat mengurangi risiko gagal panen dan meningkatkan produktivitas pertanian.

DAFTAR PUSTAKA

- [1] S. Lestari and K. Irfan Nauval, "IMPLEMENTASI DETEKSI OBJEK PENYAKIT DAUN KENTANG DENGAN METODE CONVOLUTIONAL NEUTRAL NETWORK," *J. Apl. Teknol. Inf. dan Manaj.*, vol. 3, no. 2, 2022.
- [2] K. I. Nauval and S. Lestari, "Implementasi Deteksi Objek Penyakit Daun Kentang dengan Metode Convolutional Neutral Network," *J. Apl. Teknol. Inf. dan Manaj.*, vol. 3, no. 2, 2022, doi: 10.31102/jatim.v3i2.1576.
- [3] A. J. Rozaqi, A. Sunyoto, and M. R. Arief, "Implementasi Transfer Learning pada Algoritma Convolutional Neural Network Untuk Identifikasi Penyakit Daun Kentang," *Procedia Eng. Life Sci.*, vol. 1, no. 1, 2021.
- [4] A. J. Rozaqi, A. Sunyoto, and M. rudyanto Arief, "Deteksi Penyakit Pada Daun Kentang Menggunakan Pengolahan Citra dengan Metode Convolutional Neural Network," *Creat. Inf. Technol. J.*, vol. 8, no. 1, 2021, doi: 10.24076/citec.2021v8i1.263.
- [5] A. J. Rozaqi, A. Sunyoto, and R. Arief, "Deteksi Penyakit pada Daun Kentang Menggunakan Pengolahan Citra dengan Metode Convolutional Neural Network Detection of Potato Leaves Disease Using Image Processing with Convolutional Neural Network Methods," *Creat. Inf. Technol. J.*, vol. 8, 2021.
- [6] P. Teresia Ompusunggu, "Klasifikasi Penyakit Tanaman Pada Daun Kentang Dengan Metode Convolutional Neural Network Arsitektur Mobilenet," *J. Syntax Fusion*, vol. 2, no. 09, 2022, doi: 10.54543/fusion.v2i09.217.
- [7] J. R. Aisya and A. Prasetiadi, "Klasifikasi Penyakit Daun Kentang dengan Metode CNN dan RNN," *J. Tekno Insentif*, vol. 17, no. 1, 2023, doi: 10.36787/jti.v17i1.888.
- [8] U. Khultsum and G. Taufik, "Komparasi Kinerja DenseNet 121 dan MobileNet untuk Klasifikasi Citra Penyakit Daun Kentang," *JURIKOM (Jurnal Ris. Komputer)*, vol. 10, no. 2, 2023, doi: 10.30865/jurikom.v10i2.6047.
- [9] D. Zahirah, N. Kurniati, and H. Darwis, "DIGITAL IMAGE CLASSIFICATION OF HERBAL LEAVES USING KNN AND CNN WITH GLCM FEATURES," *J. Tek. Inform.*, vol. 5, no. 1, 2024.
- [10] P. T. Ompusunggu, "KLASIFIKASI PENYAKIT TANAMAN PADA DAUN KENTANG DENGAN METODE CONVOLUTIONAL NEURAL NETWORK ARSITEKTUR MOBILENET," *J. Syntax FUSION*, vol. 2, no. 8.5.2017, 2022.
- [11] E. Salim and Suharjo, "Hyperparameter optimization of YOLOv4 tiny for palm oil fresh fruit bunches maturity detection using genetics algorithms," *Smart Agric. Technol.*, vol. 6, 2023, doi: 10.1016/j.atech.2023.100364.
- [12] A. M. Lesmana, R. P. Fadhillah, and C. Rozikin, "Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN)," *J. Sains dan Inform.*, vol. 8, no. 1, 2022, doi: 10.34128/jsi.v8i1.377.
- [13] B. Yanto, B. -, J. -, and B. H. Hayadi, "INDENTIFIKASI POLA AKSARA ARAB MELAYU DENGAN JARINGAN SYARAF TIRUAN CONVOLUTIONAL NEURAL NETWORK (CNN)," *JSAI (Journal Sci. Appl. Informatics)*, vol. 3, no. 3, 2020, doi: 10.36085/jsai.v3i3.1151.
- [14] A. K. Kurniawan, Andi Sunyoto, and Alva Hendi Muhammad, "Detection of Palm Fruit Maturity Using Convolutional Neural Network Method," *JAIA - J. Artif. Intell. Appl.*, vol. 2, no. 2, 2023, doi: 10.33372/jaia.v2i2.859.
- [15] N. Misron, N. S. K. Azhar, M. N. Hamidon, I. Aris, K. Tashiro, and H. Nagata, "Fruit battery with charging concept for oil palm maturity sensor," *Sensors (Switzerland)*, vol. 20, no. 1, 2020, doi: 10.3390/s20010226.
- [16] B. Yanto, J. Jufri, A. Lubis, B. H. Hayadi, and E. Armita, NST, "Klarifikasi Kematangan Buah Nanas Dengan Ruang Warna Hue Saturation Intensity (Hsi)," *INOVTEK Polbeng - Seri Inform.*, vol. 6, no. 1, p. 135, 2021, doi: 10.35314/isi.v6i1.1882.
- [17] T. Rahman *et al.*, "Transfer learning with deep Convolutional Neural Network (CNN) for pneumonia detection using chest X-ray," *Appl. Sci.*, vol. 10, no. 9, 2020, doi: 10.3390/app10093233.
- [18] B. Citra, R. E. D. Green, and B. Rgb, "PENERAPAN ALGORITMA DEEP LEARNING CONVOLUTIONAL NEURAL NETWORK DALAM MENENTUKAN KEMATANGAN BUAH JERUK MANIS APPLICATION OF THE DEEP LEARNING CONVOLUTIONAL NEURAL NETWORK ALGORITHM IN DETERMINING THE MURABILITY OF SWEET ORANGE FRUIT BASED ON IMAGES RED GRE," vol. 10, no. 1, pp. 59–66, 2023, doi: 10.25126/jtiik.2023105695.
- [19] Mohammad Yazdi Pusadan, Indah Safitri, and Wirdayanti, "The Image Extraction Using the HSV Method to Determine the Maturity Level of Palm Oil Fruit with the k-nearest Neighbor Algorithm," *J. RESTI*

- (*Rekayasa Sist. dan Teknol. Informasi*), vol. 7, no. 6, 2023, doi: 10.29207/resti.v7i6.5558.
- [20] B. Yanto, E. Rouza, L. Fimawahib, B. H. Hayadi, and R. R. Pratama, "Penerapan Algoritma Deep Learning Convolutional Neural Network Dalam Menentukan Kematangan Buah Jeruk Manis Berdasarkan Citra Red Green Blue (RGB)," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 1, 2023, doi: 10.25126/jtiik.20231015695.
- [21] B. Yanto, Maria Angela Kartawidjaja, Ronald Sukwadi, and Marsellinus Bachtiar, "Implementation of Hue Saturation Intensity (Hsi) Color Space Transformation Algorithm With Red, Green, Blue (Rgb) Color Brightness in Assessing Tomato Fruit Maturity," *RJOCS (Riau J. Comput. Sci.)*, vol. 9, no. 2, pp. 167–178, 2023, doi: 10.30606/rjocs.v9i2.2428.
- [22] M. Kevin Santosa, M. Hanindia Prami Swari, and A. Nugroho Sihananto, "IMPLEMENTASI ARSITEKTUR ALEXNET DAN RESNET34 PADA KLASIFIKASI CITRA PENYAKIT DAUN KENTANG MENGGUNAKAN TRANSFER LEARNING," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 5, 2024, doi: 10.36040/jati.v7i5.7337.
- [23] Y. Muliani, R. Robana, and I. Mulyati, "Aplikasi Agensia Hayati *Trichoderma harzianum* Rifai. untuk Menekan *Phytophthora infestans* (Mont.) Penyebab Penyakit Busuk Daun pada Tanaman Kentang (*Solanum tuberosum* L.)," *AGROSCRIPT J. Appl. Agric. Sci.*, vol. 5, no. 1, 2023, doi: 10.36423/agroscript.v5i1.1245.
- [24] N. Kusmana and A. D. Ambarwati, "Evaluasi Resistensi dan Daya Hasil Enam Klon Harapan Kentang Transgenik Terhadap Serangan Penyakit Hawar Daun (Evaluation of Resistance to Late Blight and Tuber Yield of Six Potential Potato Transgenic Clones)," *J. Hortik.*, vol. 28, no. 1, 2019, doi: 10.21082/jhort.v28n1.2018.p41-50.