

IMPLEMENTASI DETEKSI OBJEK PENYAKIT DAUN KENTANG DENGAN METODE CONVOLUTIONAL NEUTRAL NETWORK

Sri Lestari¹, Kurniawan Irfan Nauval²

^{1,2}Program Studi Sistem Informasi, STIKOM CKI, Jakarta, Indonesia

¹sri.lestari1203@gmail.com, ^{2*}kurniawanirfan2611@gmail.com

ABSTRAK

Kentang ialah salah satu tanaman yang potensial untuk dikembangkan. Produksi dan produktivitas kentang di Indonesia semakin menurun setiap tahunnya. Badan Pusat Statistik (BPS) mencatat produksi kentang di Indonesia mengalami penurunan 9,82%, dari 1.176.304 ton pada tahun 2009 menjadi 1.060.805 ton pada tahun 2010.[1] Kendala menurunnya produktivitas kentang disebabkan oleh serangan hama dan penyakit, sehingga memerlukan suatu sistem yang dapat membantu mendiagnosis sejak dini terhadap serangan hama dan penyakit tanaman kentang. Salah satu cara untuk mendeteksi penyakit pada tanaman kentang dengan memanfaatkan perkembangan teknologi dan informasi yaitu dengan mengembangkan ilmu kecerdasan buatan (Artificial Intelligence) serta memanfaatkan teknologi pengolahan citra digital maka hal ini bisa diatasi, jadi pada penelitian ini akan mengusulkan metode yang tepat dalam mendeteksi penyakit pada daun kentang. Klasifikasi akan dilakukan dengan tiga kelas berupa daun sehat, early blight, dan late blight menggunakan metode Deep Learning menggunakan arsitektur Convolutional Neural Network (CNN). Hasil pada penelitian ini dianggap baik karena pada epoch ke 10 dengan batch size 20 menghasilkan training akurasi 95% dan akurasi validasi 94%.

Kata Kunci : Produktivitas, *Convolutional Neural Network* (CNN), Akurasi validasi, *Deep Learning*, *Artificial Intelligence* , *early blight*, dan *late blight*.

ABSTRACT

Potato is one of the plants that has the potential to be developed. Production and productivity of potatoes in Indonesia is decreasing every year. The Central Statistics Agency (BPS) noted that potato production in Indonesia decreased by 9.82%, from 1,176,304 tons in 2009 to 1,060,805 tons in 2010.[1] Constraints to the decline in potato productivity were caused by pests and diseases, thus requiring a system which can help diagnose early potato pests and diseases. One way to detect disease in potato plants by utilizing developments in technology and information is by developing artificial intelligence and utilizing digital image processing technology so this can be overcome, so this study proposes the right method for detecting disease in potato. potato leaves. Classification will be carried out with three classes in the form of healthy leaves, early blight, and late blight using the Deep Learning method using the Convolutional Neural Network (CNN) architecture. The results of this research are considered good because the 10th epoch with a batch size of 20 produces 95% accuracy training and 94% validation accuracy.

Keywords: *Productivity*, *Convolutional Neural Network* (CNN), *Validation accuracy*, *Deep Learning*, *Artificial Intelligence* , *early blight*, and *late blight*.

1. PENDAHULUAN

Tanaman kentang memiliki banyak sekali manfaat untuk kebutuhan hidup kita sebagai manusia dan tidak asing lagi di mata masyarakat Indonesia.[2] Kentang berada pada peringkat ketiga bahan pokok yang dikonsumsi masyarakat dunia setelah beras dan gandum (International Potato Center, 2013).[3] Kentang merupakan salah satu dari sekian banyak makanan utama karena didalamnya mengandung banyak sekali karbohidrat. Dan tidak pula dipungkiri tanaman kentang pasti memiliki penyakit, jika penyakit tanaman ini dibiarkan maka dapat meningkatkan penurunan produksi pada pangan, dalam masa tanam, tanaman kentang tidak boleh teserang hama[4] maka perlunya pendekslan penyakit pada tanaman pada waktu yang tepat supaya dapat mengendalikan serta mencegah dengan lebih baik dan benar untuk penyakit tanaman. Produktivitas kentang saat ini semakin menurun disebabkan karena biaya produksi tanaman kentang tinggi[5], padahal meningkatnya permintaan kentang seiring dengan bertambahnya jumlah penduduk, taraf hidup masyarakat yang meningkat serta banyaknya penduduk luar ataupun wisatawan asing yang ke Indonesia.[6] Berdasarkan pengalaman para petani yang menanam kentang, biasanya penyakit busuk pada daun kentang timbul saat tanaman tersebut berumur 5–6 minggu setelah tanam.[7] Serangan penyakit busuk daun sangat berpotensi menyebar ke bagian lain dari tanaman kentang seperti pada tangkai, batang dan umbi kentang. Sehingga petani harus mengetahui dan memangkas secara dini daun yang sudah terinfeksi penyakit busuk daun agar mendapatkan hasil panen yang baik dan juga bagus. Diagnosis virus berdasarkan gejala sulit untuk menentukan identitas suatu virus.[8] Biaya Produksi pun bisa signifikan meningkat jika penyakit tanaman tidak terdeteksi dan disembuhkan pada tahap awal[9]

Ada beberapa penyakit daun kentang yang tidak diketahui oleh para Petani.[10] Penyakit busuk daun kentang mulai ditemukan gejalanya di sentra pertanaman kentang di pulau Jawa. Diduga bahwa jamur patogen penyebab penyakit busuk daun terbawa oleh umbi–umbi benih (bibit) kentang yang saat ini diimpor dari negara Belanda. Sedangkan penyakit daun kentang bercak kering atau disebut juga early blight[11] dapat dengan mudah diamati pada tanaman kentang yang bergejala. Gejala awal bercak kering pada daun bagian bawah, berwarna cokelat berupa tanda khas lingkaran berpusat (seperti cincin) pada bercak tersebut, sporulasi tidak nampak seperti embun putih. Penyakit bercak kering (alternaria solani) adalah penyakit pada kentang yang disebabkan oleh jamur Alternaria solani.

Adapula Penyakit hawar daun kentang disebabkan oleh jamur Phytophthora infestans merupakan salah satu penyakit penting pada tanaman kentang.[12] Penurunan produksi kentang karena serangan jamur P. infestans dapat mencapai 90%.[13], contoh penyakit lain pada daun kentang adalah penyakit layu yang diakibatkan oleh patogen Ralstonia solanacearum.[14]

Proses identifikasi[15] daun kentang secara tradisional mengalami banyak kendala akibat sifat manusia yang mempunyai kelemahan yang menyebakan hasil yang diinginkan tidak efektif.[16] Identifikasi buah-buahan, daun tanaman dan sayuran yang dilakukan secara manual tidak efisien dan kurang teliti, untuk jumlah yang cukup besar.[17] Dalam menangani masalah pada penyakit pada daun kentang ini telah banyak dilakukan, tidak hanya didalam bidang pertanian saja tetapi pada bidang teknologi pun turut andil, salahsatunya adalah pemanfaatan bidang informatika dalam mengidentifikasi penyakit yang ada pada tanaman kentang dengan menggunakan image processing atau biasa disebut pengolahan citra digital. Riset selalu dilakukan untuk menemukan

metode dan konsep yang sesuai dalam penanganan kasus pengenalan objek secara komputasi dengan pengolahan citra.[18] Dalam disiplin komputer, salah satu metode yang sering digunakan untuk identifikasi atau pengenalan objek adalah pengolahan citra.[19] Pengolahan citra merupakan cara yang efektif untuk mengidentifikasi penyakit daun kentang.[20] Pemanfaatan image processing dalam melakukan identifikasi dapat membantu para pengelola pertanian untuk memberikan penanganan secara efektif dan efisien pada tanaman yang tidak sehat atau tidak normal. Dengan berkembangnya teknologi saat ini telah banyak penelitian yang mengembangkan pengolahan citra digital dalam bidang pertanian baik untuk mengidentifikasi penyakit ataupun mengidentifikasi hasil produksi pertanian.

Salah satu pemanfaatan penelitian citra digital dalam menyelesaikan masalah pada penelitian ini adalah untuk identifikasi penyakit pada daun tanaman kentang. Penelitian ini bertujuan untuk membuat sistem yang dapat membantu para petani[21] atau pengelola pertanian dalam mengidentifikasi penyakit pada daun kentang dengan memanfaatkan data gambar daun kentang. Identifikasi daun pada tanaman kentang ini dibagi menjadi tiga bagian yaitu tanaman kentang dengan daun sehat atau normal, late blight, dan early blight. Maka pada penelitian ini akan melakukan identifikasi ini menggunakan algoritma Convolutional Neural Network (CNN) yang merupakan salah satu dari metode Deep Learning. Data yang digunakan berupa data penyakit pada daun tanaman kentang didapat dari website kaggle dengan nama PlantVillage.

2. METODOLOGI PENELITIAN

2.1 Survei Metodologi (Review Survey Protocol)

Metodologi survei ini disusun berdasarkan PICOC (Population, Intervention, Comparation, Outcomes, Context) sebagai identifikasi kebutuhan informasi dari sumber penelitian – penelitian sebelumnya dalam table 2.1 yaitu:

<i>Judul Tema Survei :</i> Implementasi Deteksi Objek Penyakit Daun Kentang dengan Metode Convolutional Neural Network	
Population	Klasifikasi, Daun Kentang, Convolutional Neutral Network dan Penyakit Daun Kentang
Intervention	Citra dataset yang didapatkan kualitasnya masih kurang layak
Comparation	-
Outcomes	Identifikasi Penyakit Daun Kentang
Context	<i>Dataset public</i>

Dalam melakukan mencarian dari sumber-sumber penelitian sebelumnya dilakukan tahapan dalam mendapatkan jurnal-jurnal penelitian yang telah dipublikasikan untuk itu dilakukan Strategi Seleksi Studi atau Studies Selection Strategy yaitu melakukan tahapan sebagai berikut:

2.2 Data Penelitian

Dataset yang digunakan pada penelitian ini berupa gambar daun tanaman kentang yang dibagi menjadi tiga kelas yaitu late blight yang ditampilkan pada Gambar 2 (a), early blight yang ditampilkan pada Gambar 2 (b), dan daun sehat yang ditampilkan pada Gambar 2 (c). Dataset ini didapatkan dari website Kaggle dengan nama “PlantVillage Dataset” yang diunggah oleh Tairu Oluwafemi Emmanuel dan perubahan yang terakhir dilakukan pada oktober 2018.

2.3 Data Collection

Dataset Collection merupakan tahapan pengumpulan data yang akan digunakan pada penelitian ini dalam menentukan penyakit daun pada tanaman kentang. Karena pada penelitian ini bersifat supervised learning dimana pada proses klasifikasi menggunakan data yang sudah ada yang memiliki label dari masing-masing kelas, maka data daun tanaman kentang yang digunakan memiliki label atau kelas yang dibagi menjadi tiga yaitu late blight, early blight, dan daun sehat atau normal. Pada dataset Collection ini digunakan juga Augmentation Image, yaitu sebuah teknik yang digunakan untuk memperluas ukuran kumpulan data ketika terjadi keterbatasan dataset dengan memodifikasi gambar yang ada dalam kumpulan data. Proses image augmentation ini dilakukan agar kualitas model meningkat.

2.4 Preprocessing Data

Preprocessing data merupakan tahap persiapan sebelum data diolah dan digunakan untuk melakukan klasifikasi. Pada tahap ini persiapan data yang dilakukan adalah menentukan jumlah data yang digunakan yaitu 1152 gambar dari 3 kelas, pembagian kelasnya adalah late blight, early blight dan daun sehat.

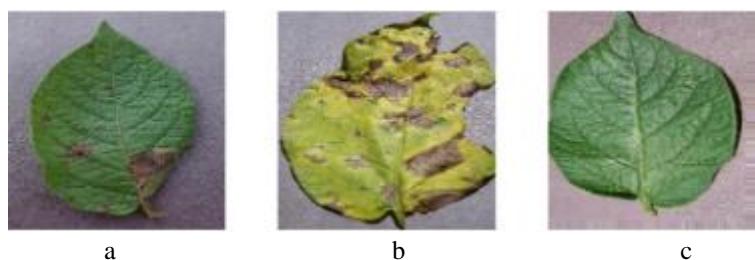
2.5 Classification

Pada Tahap selanjutnya adalah melakukan klasifikasi gambar dengan menggunakan metode Convolutional Neural Network (CNN). Algoritma CNN termasuk dalam metode supervised learning dimana identifikasi suatu gambar dengan melatih data gambar yang sudah ada dan menargetkan variabel gambar. Convolutional layer CNN membantu jaringan saraf pada CNN mengenali daun kentang berdasarkan attribut-atribut yang dimilikinya. Jaringan saraf dapat mengenali gambar daun kentang berdasarkan piksel-piksel yang ada didalam gambar.

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Dataset

Dataset ini merupakan dataset daun tanaman kentang yang terbagi kedalam 3 kelas yaitu late blight, early blight serta daun sehat (Gambar 3.1). Dataset ini berjumlah 900 data dengan rincian masing-masing kelas memiliki 300 data. Dataset ini kemudian diletakkan pada folder google drive.



Gambar 3. 1 Daun late blight (a), daun *early blight* (b), daun sehat (c)

3.2 Praproses Data

Langkah yang dilakukan pada praproses data adalah memuat library yang dibutuhkan serta memuat dataset berupa citra daun tanaman kentang. Langkah pertama yaitu memuat library (Gambar 3.2).

```
# import library yang dibutuhkan
import numpy as np
import os
from sklearn.metrics import confusion_matrix, classification_report
import seaborn as sn; sn.set(font_scale=1.4)
from sklearn.utils import shuffle
import matplotlib.pyplot as plt
import cv2
import tensorflow as tf
from tqdm import tqdm
import random
from random import randrange
```

Gambar 3. 2 Memuat Library

Setelah library dimuat langkah selanjutnya adalah memuat dataset (Gambar 3.3).

```
# membuat fungsi load_data untuk memuat data citra dan data label dari folder dataset
def load_data():
    datasets = ['./content/drive/MyDrive/dataset/train',
                './content/drive/MyDrive/dataset/test']
    output = []
    # perulangan melalui training dan tes citra
    for dataset in datasets:
        images = []
        labels = []
        print("Memuat {}".format(dataset))
        # perulangan setiap folder untuk mendapatkan kategori
        for folder in os.listdir(dataset):
            label = class_names_label[folder]
            # perulangan setiap citra yang ada di folder dataset
            for file in tqdm(os.listdir(os.path.join(dataset, folder))):
                # mendapatkan nama-nama citra
                img_path = os.path.join(os.path.join(dataset, folder), file)
                # membuka dan merubah ukuran citra
                image = cv2.imread(img_path)
                image = cv2.cvtColor(image, cv2.COLOR_BGR2RGB)
                image = cv2.resize(image, IMAGE_SIZE)
                # menambahkan citra dan label sesuai output
                images.append(image)
                labels.append(label)
        images = np.array(images, dtype = 'float32')
        labels = np.array(labels, dtype = 'int32')
        output.append((images, labels))
    return output
# menampilkan proses memuat citra dari dataset
(train_images, train_labels), (test_images, test_labels) = load_data()
train_images, train_labels = shuffle(train_images, train_labels, random_state=10)
```

Gambar 3. 3 Memuat Database

```

n_train = train_labels.shape[0] # menghitung jumlah citra train
n_test = test_labels.shape[0] # menghitung jumlah citra test

print ("Jumlah citra training : {}".format(n_train))
print ("Jumlah citra testing : {}".format(n_test))
print ("Ukuran citra : {}".format(IMAGE_SIZE))

Jumlah citra training : 900
Jumlah citra testing : 300
Ukuran citra : (150, 150)

```

Gambar 4. 4 Jumlah citra daun tanaman kentang untuk data training dan testing

Setelah dataset dimuat selanjutnya adalah mengkonfirmasi jumlah dataset citra daun tanaman kentang untuk data training dan data testing.

3.3 Desain Model

Pada tahap ini model akan dibuat dan dijelaskan model yang ada pada metode Convolutional Neural Network (CNN). Setelah dilakukan praproses data, langkah selanjutnya adalah membuat desain model dengan metode CNN. Ada tiga tahap yaitu membangun model, menyusun model serta training data citra.

```

%%time

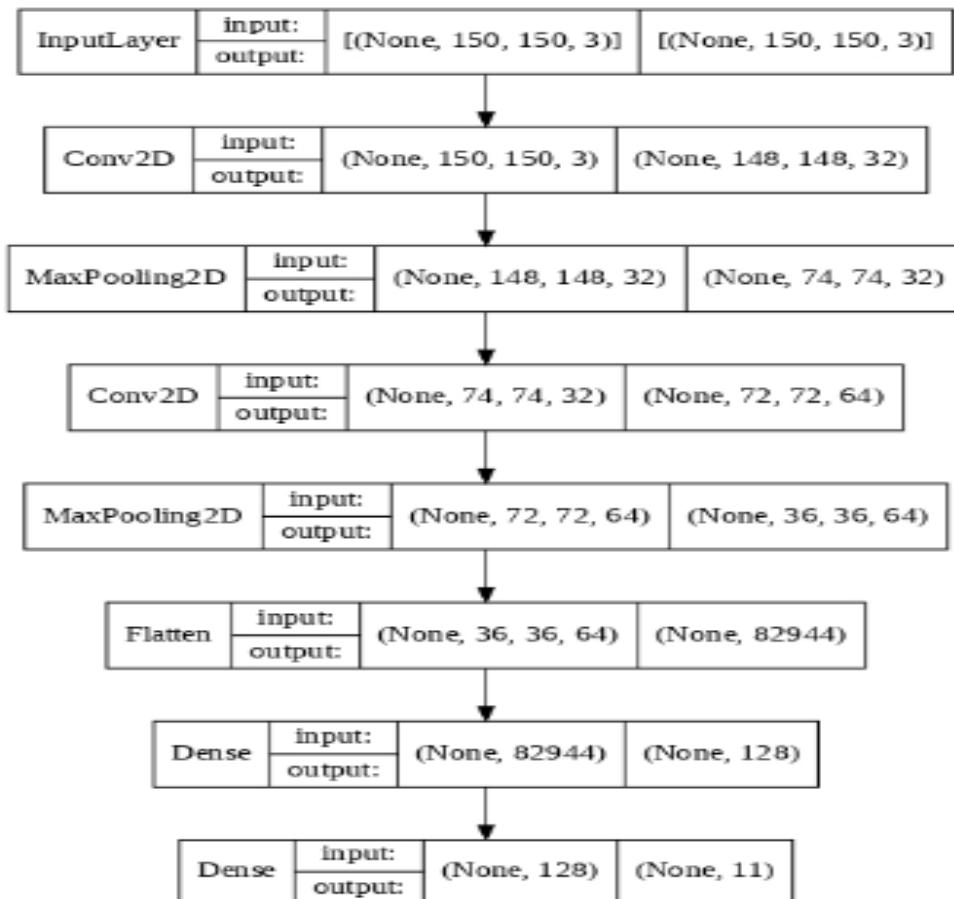
import time
from time import time
import pandas as pd
from tensorflow.keras.models import Sequential
from tensorflow.keras.utils import plot_model

#Training model Sequential
model = tf.keras.Sequential([
    tf.keras.layers.Conv2D(32, (3, 3), activation = 'relu',
                          input_shape = (150, 150, 3)),
    tf.keras.layers.MaxPooling2D(2,2),
    tf.keras.layers.Conv2D(64, (3, 3), activation = 'relu'),
    tf.keras.layers.MaxPooling2D(2,2),
    tf.keras.layers.Flatten(),
    tf.keras.layers.Dense(128, activation=tf.nn.relu),
    tf.keras.layers.Dense(11, activation=tf.nn.softmax)
])
model.compile(optimizer = 'adam', loss = 'sparse_categorical_crossentropy',
              metrics=['accuracy'])
model.summary()

```

Gambar 3. 4 Membangun dan menyusun model

Pada gambar 3.4 diatas adalah implementasi tahap membangun dan Menyusun model yang menggunakan library tensor untuk metode CNN. Adapun tahap pembangunan dan penyusunan model ini melewati 5 tahapan yaitu pertama mengekstrak fitur dari citra. Kedua mengubah fitur tersebut menjadi setengah ukuran. Ketiga mengubah format fitur gambar dari array 2 dimensi menjadi array 1 dimensi dengan nilai 150 150 3 pixel. Keempat array tersebut diberi nilai x, serta mengembalikan maks(x, 0). Kelima penentuan 6 neuron, probabilitas bahwa fitur gambar termasuk dalam salah satu kelas.



Gambar 3.5 Hasil tahap membangun dan menyusun model

Pada gambar 3.5 diatas merupakan hasil dari 5 tahap pembangunan dan penyusunan model. Tahap pertama disebut dengan Conv2D. Tahap kedua disebut dengan MaxPooling2D. Tahap ketiga disebut Flatten. Tahap keempat disebut Relu. Tahap kelima disebut Softmax. Selanjutnya masuk ke tahap training citra daun tanaman kentang. Tahap ini dilakukan dengan 20 kali epoch (gambar 3.6).

```
history = model.fit(train_images, train_labels, batch_size=128, epochs=20, validation_split = 0.2)
```

Gambar 3.6 Tahap training citra daun dan tanaman kentang dengan 20 epoch
Adapun setelah dilakukan epoch sebanyak 20 kali didapatkan hasil akurasi 100% dan val accuracy 94% (gambar 3.7).

```
Epoch 20/20
6/6 [=====] - 1s 86ms/step - loss: 0.0049 - accuracy: 1.0000 - val_loss: 0.1452 - val_accuracy: 0.9444
```

Gambar 3.7 Hasil tahap training citra daun tanaman kentang dengan 20 epoch

Karena telah mendapatkan hasil akurasi yang cukup tinggi maka model disimpan dengan ekstensi .h5. Output dari model tersebut juga disimpan dalam bentuk ekstensi .csv. Kedua file hasil model ini disimpan kedalam folder google drive. Langkah penyimpanan ini ada pada gambar 3.8.

```

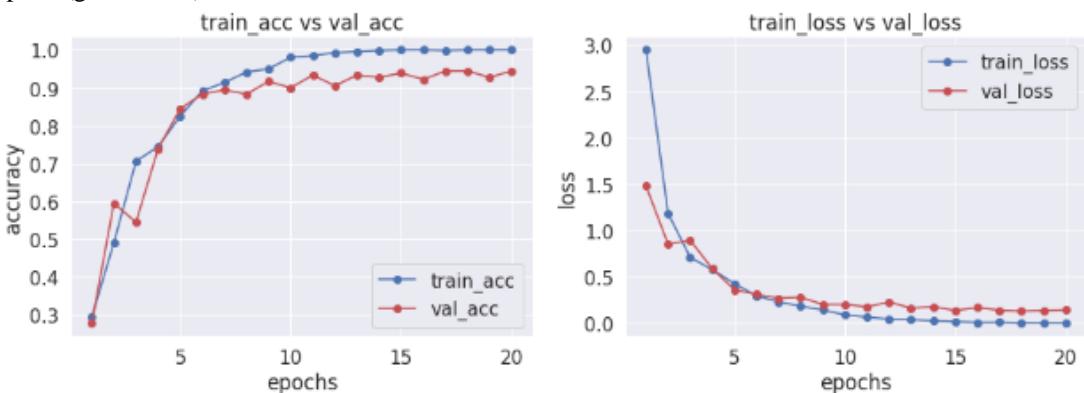
# simpan model
filename = '/content/drive/MyDrive/daunkentang/model_e20/model_Sequensial.h5'
model.save(filename)
#print('>Saved model to %s' % filename)

# simpan model report ke csv
model_csv = pd.DataFrame(history.history)
csv_file = '/content/drive/MyDrive/daunkentang/model_e20/model_Sequensial.csv'
with open(csv_file, mode="w") as f:
    model_csv.to_csv(f)
#print('>Saved report to %s' % csv_file)

```

Gambar 3.8 Penyimpanan model

Langkah berikutnya adalah menampilkan visualisasi nilai accuracy dan loss sebanyak 20 epoch (gambar 3.9).



Gambar 3.9 Visualisasi nilai accuracy dan loss sebanyak 20 epoch

Pada gambar 3.9 diatas terlihat bahwa grafik nilai akurasi mulai dari epoch 1 hingga epoch 20 terlihat semakin meningkat. Sedangkan grafik nilai loss mulai dari epoch 1 hingga epoch 20 terlihat menurun.

3.4 Hasil Pengujian

Setelah pemodelan berhasil dilakukan maka langkah selanjutnya adalah melakukan pengujian. Proses pengujian ini akan menghasilkan nilai akurasi untuk model yang telah dibuat. Setelah dilakukan evaluasi model maka didapatkan nilai akurasi sebesar 94%.

```

# Mengevaluasi kinerja model pada set pengujian
test_loss, test_acc = model.evaluate(test_images, test_labels)
print("Accuracy : {:.2f}%".format(test_acc*100))
print("Loss      : {:.3f}".format(test_loss))

10/10 [=====] - 0s 20ms/step - loss: 0.1694 - accuracy: 0.9400
Accuracy : 94.00%
Loss      : 0.169

```

Gambar 3.10 Pengujian

Pada gambar 3.10 dapat terlihat bahwa nilai akurasi pada model adalah 94%. Artinya model tersebut sangat baik. Pengujian juga dilakukan untuk menampilkan random image yang terprediksi labelnya dengan benar (gambar 4.15).

```
predictions = model.predict(test_images)      # Vector probabilitas
pred_labels = np.argmax(predictions, axis = 1) # Mengambil probabilitas tertinggi
display_random_image(class_names, test_images, pred_labels)
```

Gambar 4. 5 Pengujian random image

Hasilnya model tersebut mampu menampilkan random image yang terprediksi labelnya dengan benar (gambar 4.16). Pada gambar tersebut terlihat bahwa image yang terpilih memiliki probabilitas label citra daun tanaman kentang late blight.



Gambar 4. 6 Hasil pengujian random image

Selanjutnya pengujian dilakukan juga dengan mengecek citra mana saja yang gagal dalam klasifikasi menggunakan model tersebut (gambar 4.17).

```
# Kita cek citra mana yang gagal dalam klasifikasi
def print_mislabeled_images(class_names, test_images, test_labels, pred_labels):
    BOO = (test_labels == pred_labels)
    mislabeled_indices = np.where(BOO == 0)
    mislabeled_images = test_images[mislabeled_indices]
    mislabeled_labels = pred_labels[mislabeled_indices]

    title = "Contoh citra yang gagal dalam klasifikasi:"
    display_examples(class_names, mislabeled_images, mislabeled_labels)
```

Gambar 4. 7 Mengecek citra yang gagal dalam klasifikasi

Hasilnya dari 100 citra yang diuji ada 4 citra yang gagal dalam klasifikasi menggunakan model tersebut. Adapun citra yang gagal beserta prediksi labelnya ada pada gambar 4.18.



Gambar 4. 8 Hasil citra yang gagal dalam klasifikasi

3.5 Ekstraksi fitur dengan VGG16

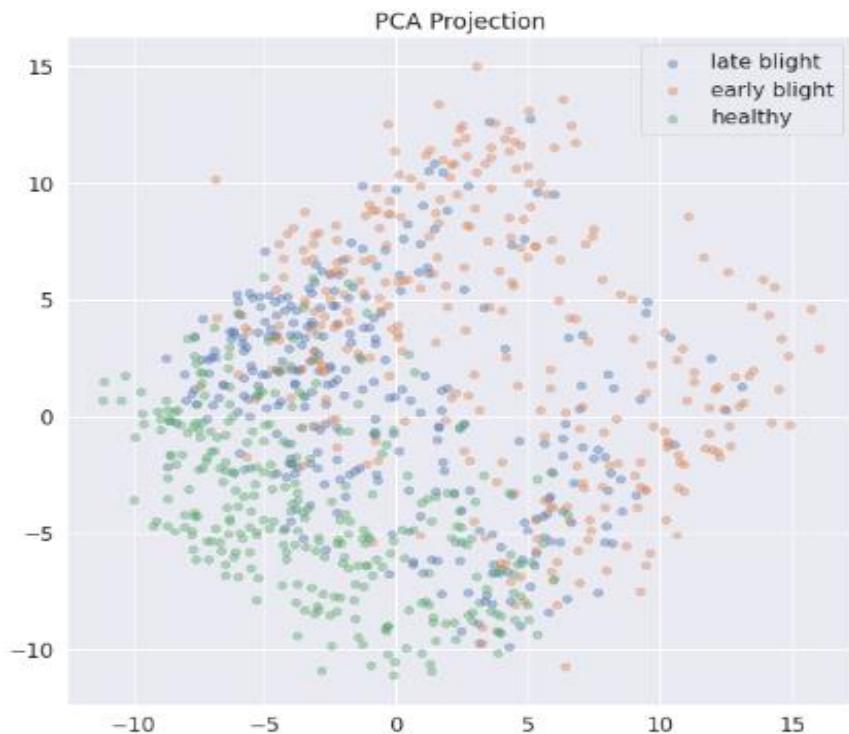
VGG16 merupakan salah satu alat untuk mengekstraksi fitur yang ada pada library keras.

```
from keras.applications.vgg16 import VGG16
from keras.preprocessing import image
from keras.applications.vgg16 import preprocess_input

model = VGG16(weights='imagenet', include_top=False)
```

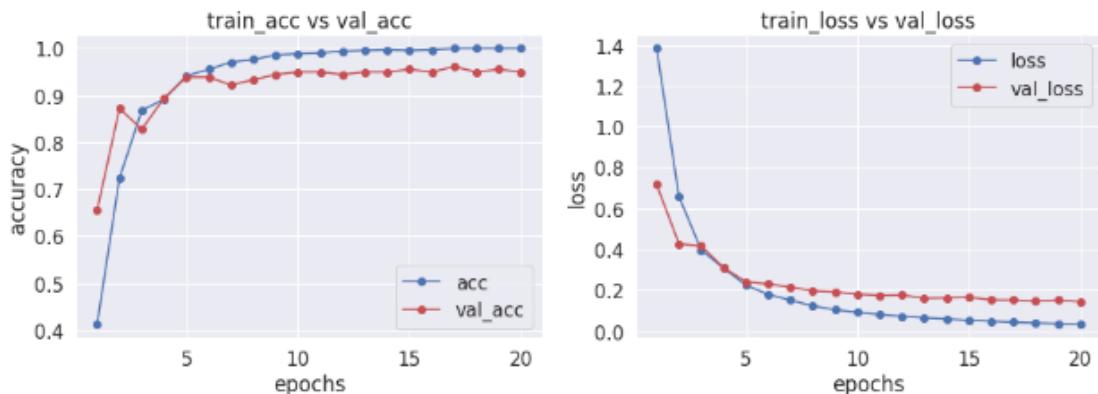
Gambar 4. 9 Deklarasi ekstraksi fitur dengan VGG16

Setelah deklarasi ekstraksi fitur dengan VGG16, selanjutnya memvisualisasikan fitur tersebut melalui Principal component analysis (PCA) (gambar 4.20).



Gambar 4. 10 Visualisasi fitur melalui PCA

Tahap selanjutnya adalah melatih data training menggunakan model yang telah melalui proses ekstraksi fitur dengan VGG16. Pelatihan ini menggunakan epoch sebanyak 20 epoch. Adapun hasil dari pelatihan ini yaitu nilai akurasi dan nilai loss divisualisasikan kedalam grafik pada gambar 4.21.



Gambar 4. 11 Hasil nilai akurasi dan nilai loss

Pada gambar 4.21 diatas dapat dilihat bahwa nilai akurasi mulai dari epoch 1 hingga epoch 20 terlihat semakin meningkat. Sedangkan grafik nilai loss mulai dari epoch 1 hingga epoch 20 terlihat menurun. Maksimal nilai akurasi adalah 100% sedangkan minimal nilai loss adalah 0,0. Tahap selanjutnya yaitu menguji model yang telah melalui proses ekstraksi fitur dengan VGG16 tersebut (gambar 4.22).

```
test_loss, test_acc = model2.evaluate(test_features, test_labels)
print("Accuracy : {:.2f}%".format(test_acc*100))
print("Loss      : {:.3f} ".format(test_loss))

10/10 [=====] - 0s 3ms/step - loss: 0.1527 - accuracy: 0.9333
Accuracy : 93.33%
Loss      : 0.153
```

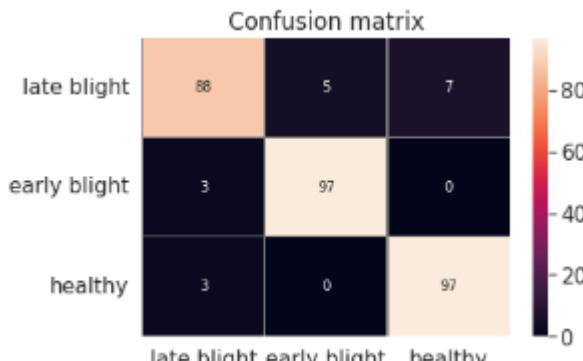
Gambar 4. 12 Hasil nilai akurasi dan nilai loss

Pada gambar 4.22 terlihat bahwa nilai akurasi dari hasil pengujian model yang telah melalui proses ekstraksi fitur dengan VGG16 adalah 93,33%. Ternyata nilai akurasi model yang telah melalui proses ekstraksi fitur dengan VGG160 tersebut kurang baik dibandingkan model dengan metode sebelumnya yaitu CNN.

3.6 Pembahasan

Dari pemaparan hasil pengujian terhadap deteksi citra daun tanaman kentang diatas diketahui model dengan metode CNN memiliki nilai akurasi sebesar 94%. Hasil akurasi ini lebih tinggi dibandingkan dengan deteksi citra daun tanaman kentang dengan ekstraksi fitur menggunakan VGG16 yaitu 93,33. Model yang dihasilkan dengan metode CNN sesuai harapan. Hal ini karena tingkat akurasi model diatas 70%.

Adapun hasil akurasi tersebut dapat dibahas turunan variabelnya pada Confusion Matrix. Confusion matrix adalah suatu metode yang biasanya digunakan untuk melakukan perhitungan akurasi pada konsep data mining atau Sistem Pendukung Keputusan. Pada pengukuran kinerja menggunakan confusion matrix, terdapat 4 (empat) istilah sebagai representasi hasil proses klasifikasi. Keempat istilah tersebut adalah True Positive (TP), True Negative (TN), False Positive (FP) dan False Negative (FN). Namun dalam penelitian ini istilah tersebut tidak digunakan. Pada penelitian ini digunakan istilah 3 kelas label yaitu late blight, early blight serta healthy (gambar 4.23).



Gambar 4. 13 Confusion Matrix

Pada gambar 4.23 diatas jumlah citra daun tanaman kentang dengan label late blight yang terdeteksi benar adalah sebanyak 88 gambar. Sedangkan jumlah citra daun tanaman kentang dengan label early blight yang terdeteksi benar adalah sebanyak 97 gambar. Selanjutnya jumlah citra daun tanaman kentang dengan label healthy yang terdeteksi benar adalah sebanyak 97 gambar.

4. KESIMPULAN

4.1 Kesimpulan

Berdasarkan penelitian yang telah dilakukan serta pembahasan yang telah diuraikan pada bab IV mengenai deteksi citra daun tanaman kentang menggunakan metode CNN dihasilkan kesimpulan sebagai berikut:

1. Sistem dibangun dengan menggunakan Sistem Operasi Windows 10 , python 3.6 serta jupyter notebook. deteksi citra daun tanaman kentang menggunakan metode CNN ini dilakukan dengan 4 tahap utama yaitu penyiapan dataset (praposes data), pembuatan model serta pemaparan hasil pengujian.
2. Penyiapan dataset dilakukan dengan mengambil data dari “PlantVillage Dataset” pada website Kaggle yang diunggah oleh Tairu Oluwafemi Emmanuel. Dataset ini merupakan dataset daun tanaman kentang yang terbagi kedalam 3 kelas yaitu late blight, early blight serta daun sehat. Dataset ini berjumlah 900 data dengan rincian masing-masing kelas memiliki 300 data. Praposes data dilakukan dengan memuat library yang dibutuhkan serta memuat dataset berupa citra daun tanaman kentang.
3. Library yang dibutuhkan diatas secara garis besar adalah untuk memuat dataset gambar citra daun kentang, untuk membuat desain model menggunakan metode CNN, serta menampilkan nilai confusion matrix hasil pengujian. Setelah selesai melakukan praposes data, selanjutnya dilakukan pembuatan desain model dan pengujian. Dari hasil pengujian model tersebut didapatkan nilai hasil akurasi sebesar 94%. Selanjutnya peneliti melakukan ekstraksi fitur dengan metode VGG16 untuk meningkatkan hasil akurasi. Namun ternyata tidak sesuai harapan karena hasil akurasinya lebih rendah yaitu 93,3%. Sehingga dihasilkan kesimpulan bahwa deteksi citra daun tanaman kentang menggunakan metode CNN sesuai harapan. Adapun hasil confusion matrix dari pengujian yang dilakukan menunjukkan jumlah citra daun tanaman kentang dengan label late blight yang terdeteksi benar adalah sebanyak 88 gambar. Sedangkan jumlah citra daun tanaman kentang dengan label early blight yang terdeteksi benar adalah sebanyak 97 gambar. Selanjutnya jumlah citra daun tanaman kentang dengan label healthy yang terdeteksi benar adalah sebanyak 97 gambar

4.2 Saran

Dari hasil penelitian, penulis memberikan saran agar pada tahap selanjutnya dilakukan pengembangan penelitian selanjutnya antara lain:

1. Menggunakan algoritma lain untuk proses klasifikasi data misalnya algoritma naivebayes, algoritma Bidirectional Encoder Representations from Transformers (BERT), atau algoritma Recurrent neural network (RNN).
2. Mencari topik daun tanaman lain dalam topik deteksi citra daun tanaman sebagai perbandingan untuk proses klasifikasi daun tanaman.

DAFTAR PUSAKA

- [1] S. P. G. Widestra, N. Hidayat, and R. K. Dewi, “Sistem Diagnosis Penyakit Tanaman Kentang Menggunakan Sistem Diagnosis Penyakit Tanaman Kentang Menggunakan Metode K-Nearest Neighbor Syndu,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 4, pp. 4020–4026, 2019.
- [2] Mehri Paniza, Rusbandi, and Derry Alamsyah, “Identifikasi Jenis Buah Pir Berdasarkan Bentuk Menggunakan Metode HOG dan JST,” *J. Algoritm.*, vol. 2, no. 1, pp. 62–72, 2021.
- [3] F. Nainggolan, H. D. Hutahaean, and A. Gea, “Sistem Pakar Mendeteksi Penyakit Pada Tanaman Sayur Sawi Dengan Metode Bayes,” *J. Armada Inform.*, vol. 2, no. 2, pp. 109–118, 2018, doi: 10.36520/jai.v2i2.31.
- [4] N. Ahmad and Iskandar, “Metode Forward Chaining untuk Deteksi Penyakit Pada Tanaman Kentang,” *JINTECH J. Inf. Technol.*, vol. 1, no. 2, pp. 7–20, 2020, doi: 10.22373/jintech.v1i2.592.
- [5] L. Lehar, M. K. Salli, and H. M. C. Sine, “APLIKASI PUPUK ORGANIK DAN Trichoderma sp TERHADAP HASIL,” *Hijau Cendekia*, pp. 29–34, 2013.
- [6] P. Pada and T. Kentang, “APLIKASI BIOPESTISIDA Streptomyces sp . DALAM MENGENDALIKAN DI DATARAN MEDIUM APPLICATION OF BIOPESTICIDES STREPTOMYCES SP . IN CONTROLLING DISEASE IN POTATO (SOLANUM TUBEROSUM L .) PLANTS IN THE MEDIUM PLAIN PENDAHULUAN Kentang (S . tuberosum L .) meru,” vol. 30, no. 2, pp. 109–124, 2020.
- [7] L. Amatullah, I. Ein, and M. M. Santoni, “Identifikasi Penyakit Daun Kentang Berdasarkan Fitur Tekstur dan Warna Dengan Menggunakan Metode K-Nearest Neighbor,” *Semin. Nas. Mhs. Ilmu Komput. dan Apl.*, no. April, pp. 783–791, 2021.
- [8] Damayanti and Kartika, “Deteksi Virus-Virus pada Kentang di Jawa Barat dengan Menggunakan Teknik Molekuler (Detection of Viruses on Potato in West Java by Using Molecular Techniques),” *J. Hortik.*, vol. 25, no. 2, pp. 171–179, 2015.
- [9] P. U. Rakhmawati, Y. M. Pranoto, and E. Setyati, “Klasifikasi Penyakit Daun Kentang Berdasarkan Fitur Tekstur dan Fitur Warna Menggunakan Support Vector Machine,” *Semin. Nas. Teknol. dan Rekayasa*, pp. 1–8, 2018.
- [10] V. I. Safitri, “Deteksi Penyakit Tanaman Kentang Menggunakan Metode Certainty Factor,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 1, no. 1, pp. 798–805, 2017.
- [11] S. Ilahiyah and A. Nilogiri, “Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network,” *JUSTINDO (Jurnal Sist. dan Teknol. Inf. Indones.)*, vol. 3, no. 2, pp. 49–56, 2018.
- [12] A. Fitriana and L. Hakim, “Endophytic Fungus effectiveness Origin Root Crops Potatoes in

- Compost Media Skin Diseases Coffee to Suppress Development Potato Leaf blight (Phytophtora infestans)," *J. Agrista*, vol. 23, no. 1, pp. 9–14, 2019.
- [13] W. Nawfetrias *et al.*, "Pengendalian Hayati Penyakit Hawar Daun Tanaman Kentang Dengan Agens Hayati Jamur-jamur Antagonis Isolat Lokal," *Bioma Berk. Ilm. Biol.*, vol. 2, no. 2, p. 51, 2018, doi: 10.14710/bioma.10.2.51-57.
- [14] J. Fauzul Izza, L. Qurata Aini, and R. Rizkyta Kusuma, "Pemanfaatan Rhizobakteri dari Gulma di UB Forest sebagai Agen Antagonis Penyakit Layu Bakteri pada Kentang," *Biotropika - J. Trop. Biol.*, vol. 6, no. 2, pp. 54–63, 2018, doi: 10.21776/ub.biotropika.2018.006.02.03.
- [15] B. M. Sari, "Identifikasi Tingkat Kematangan Buah Strawberry Berdasarkan Warna RGB dengan Menggunakan Metode Regionprops," *Terap. Inform. Nusant.*, vol. 1, no. 5, pp. 225–230, 2020, [Online]. Available: <https://ejurnal.seminar-id.com/index.php/tin/article/download/460/328>.
- [16] E. Utama, F. Yapputra, and G. Gasim, "Identifikasi Jenis Mangga Berdasarkan Bentuk Menggunakan Fitur HOG dan Jaringan Syaraf Tiruan," *J. Ilm. Inform. Glob.*, vol. 9, no. 1, pp. 1–6, 2018, doi: 10.36982/jig.v9i1.437.
- [17] S. A. Syakri, M. Mulyadi, and Z. K. Simbolon, "Identifikasi Tingkat Kebulatan Buah Pepaya Berdasarkan Luas Objek Dengan Pengolahan Citra," *J. Infomedia*, vol. 2, no. 2, 2018, doi: 10.30811/v2i2.517.
- [18] M. Widyaningsih, "Identifikasi Kematangan Buah Apel Dengan Gray Level Co-Occurrence Matrix (GLCM)," *J. SAINTEKOM*, vol. 6, no. 1, p. 71, 2017, doi: 10.33020/saintekom.v6i1.7.
- [19] G. Gasim, "Identifikasi Kadar Semen dan Pasir Melalui Citra Permukaan Menggunakan Teknik Blok Citra," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 7, no. 2, pp. 188–199, 2020, doi: 10.35957/jatisi.v7i2.371.
- [20] E. F. Himmah, M. Widyaningsih, and M. Maysaroh, "Identifikasi Kematangan Buah Kelapa Sawit Berdasarkan Warna RGB Dan HSV Menggunakan Metode K-Means Clustering," *J. Sains dan Inform.*, vol. 6, no. 2, pp. 193–202, 2020, doi: 10.34128/jsi.v6i2.242.
- [21] D. S. Runtunuwu, J. E. X. Rogi, and J. H. Palendeng, "IDENTIFIKASI VARIETAS KENTANG ‘SUPERJOHN’ BERDASARKAN PENANDA RAPD (Random Amplified Polymorphic DNA)," *Eugenia*, vol. 17, no. 1, 2011, doi: 10.35791/eug.17.1.2011.7140.