

IDENTIFIKASI DAN KLASIFIKASI PENYAKIT PADA TANAMAN KOPI ARABICA DENGAN METODE CNN DAN TRANSFER LEARNING DENSENET-201

Irmawan^{1*}, Rendiansyah¹, Gustini² dan S. A. Harahap¹

¹ Teknik Elektro, Universitas Sriwijaya

² Teknik Mesin, Universitas Sriwijaya

Corresponding author: irmawan@unsri.ac.id

ABSTRAK: Kopi adalah tanaman tropis dengan harga jual yang relatif tinggi dan berfungsi sebagai sumber devisa bagi Indonesia. Kualitas dan produksi kopi akan terpengaruh jika rentan terhadap serangan. Penyakit yang terkait dengan perubahan iklim meliputi cuaca, suhu, kelembapan, tanah, perawatan tanaman yang tidak memadai, dan ketinggian tanah. Seiring dengan kemajuan teknologi, hal itu menjadi semakin diperlukan. Metode kecerdasan buatan dapat diaplikasikan untuk membantu petani dalam mengidentifikasi berbagai jenis penyakit kopi, salah satunya metode Deep Learning. Penelitian untuk identifikasi dan klasifikasi penyakit pada bidang pertanian dengan menggunakan metode Deep Learning telah menghasilkan peningkatan yang luar biasa. Penelitian dengan memanfaatkan deep learning telah dilakukan untuk mendeteksi apakah daun tanaman kopi Arabica mengidap penyakit Cercospora, Leaf Rust, Miner dan Phoma atau sehat. Pengujian metode CNN alexnet dengan akurasi 94,2% dan Transfer learning Densenet-201 dengan akurasi 97,2%.

Kata kunci : Kopi Arabica; Deep learning; CNN; Alexnet; Densenet-201

ABSTRACT: Coffee is a tropical plant with a relatively high selling price and serves as a source of foreign exchange for Indonesia. The quality and production of coffee will be affected if it is vulnerable to attacks. Diseases related to climate change include weather, temperature, humidity, inadequate soil care, and elevation. Along with technological advancements, it has become increasingly necessary. Artificial intelligence methods can be applied to assist farmers in identifying various types of coffee diseases, one of which is the Deep Learning method. Research on the identification and classification of diseases in the agricultural field using Deep Learning methods has yielded remarkable improvements. Research utilizing deep learning has been conducted to detect whether Arabica coffee plant leaves are affected by Cercospora, Leaf Rust, Miner, and Phoma diseases or if they are healthy. Testing the AlexNet CNN method achieved an accuracy of 94.2%, while the Transfer Learning with DenseNet-201 reached an accuracy of 97.2%.

Keywords: Arabica coffee; Deep learning; CNN; AlexNet; DenseNet-201

PENDAHULUAN

Pertanian merupakan salah satu sektor terpenting bagi bangsa Indonesia. Pertanian menjadi sektor penyedia ketahanan pangan masyarakat, membuka lapangan pekerjaan, menjadi instrumen pengentasan kemiskinan, serta sumber pendapatan masyarakat. Hal tersebut didukung dengan kontribusi pertanian yang sangat signifikan terhadap pencapaian tujuan program Sustainable Development Goals (SDG's) kedua, yaitu tidak ada kelaparan, mencapai ketahanan pangan, perbaikan nutrisi, serta mendorong budidaya pertanian yang berkelanjutan. Selain itu sektor pertanian memberikan kontribusi terhadap perekonomian Indonesia, dimana kehutanan, dan perikanan

menyumbang sebesar 13,28 persen. Namun pada tahun 2021, hasil Survei KSA menyatakan bahwa luas lahan panen dan produksi kopi di Indonesia mengalami penurunan sebanyak 245,47 ribu hektar (2,30 %) serta 140,73 ribu ton (0,45 %) dibandingkan dengan produksi beras tahun 2022 (Ruvanda, et al, 2022). Adanya penurunan lahan panen serta hasil produksi tersebut tentu akan memberikan dampak bagi ketahanan pangan serta perekonomian Indonesia kedepannya.

Produksi pertanian, perencanaan suksesi, penerus, dan penggunaan lahan pertanian secara signifikan dipengaruhi oleh populasi pertanian yang menua (Sidharta, 2022). Data yang dikutip dari katadata.co.id menyatakan bahwa populasi petani di Indonesia hanya sekitar 28,5% pada 2019, padahal tiga dekade sebelumnya


populasinya mencapai 55,5% dari total angkatan kerja. Ditinjau dari usia para petani, dominasi usia adalah pada 35-55 tahun (Juswadi, 2023). Oleh sebab itu lambat laun jumlah para petani akan semakin berkurang seiring waktu apabila regenerasi petani tidak dilanjutkan. Regenerasi petani menjadi syarat penting untuk memastikan keberlanjutan pertanian di Indonesia (Sidharta, 2022). Hasil sebuah peneliti menyatakan bahwa krisis petani muda di Indonesia adalah akibat dari kecenderungan keinginan pemuda untuk bekerja di sektor industri dengan penggunaan teknologi masa kini dibanding bekerja di sektor pertanian yang dianggap masih menggunakan teknologi tradisional (Arvianti, 2019). Dengan demikian adanya modernisasi pada sistem pertanian merupakan salah satu hal yang dapat menarik minat para pemuda ke sektor pertanian.

Di era modernisasi saat ini segala hal telah terintegrasi dengan menggunakan mesin dan tidak bekerja dengan hanya mengandalkan kekuatan manusia saja, tentu sektor pertanian juga diarahkan untuk disesuaikan dengan era saat ini. Modernisasi pertanian juga sejalan dengan salah satu isu pertanian yang dibahas pada presidensi G-20 2022 dimana Indonesia menjadi tuan rumah. Kepala biro kerja sama luar negeri Kementerian Pertanian, Ade Candradijaya yang dikutip oleh republica.co.id menyatakan bahwa tiga isu prioritas yang diangkat dalam deklarasi para menteri pertanian yaitu membangun sistem pangan dan pertanian yang tangguh dan berkelanjutan, mempromosikan perdagangan pangan yang terbuka, adil, dan dapat diprediksi serta transparan, serta mendorong bisnis pertanian yang inovatif melalui pertanian digital untuk memperbaiki kehidupan petani di wilayah pedesaan (Thoriq, et al., 2020). Pada kenyataannya beberapa kegiatan di sektor pertanian saat ini perlahan sudah mengarah ke modernisasi pertanian seperti proses pembajakan sawah, penanaman kopi, pemupukan, hingga panen yang sudah menggunakan alat bantu mesin yang memadai. Namun mesin hanya membantu, petani tetap menjadi orang yang mengetahui kondisi lahannya serta kualitas sawahnya sehingga kegiatan pengecekan kualitas kopi masih dilakukan secara manual hingga saat ini. Pengecekan tersebut tentu sangat penting mengingat 25% gagal panen kopi terjadi akibat penyakit daun kopi (Faizin, 2023). Pengecekan secara manual akan menghabiskan waktu yang cukup lama sesuai luas lahan, selain itu diagnosa penyakit kopi yang dilakukan oleh petani sendiri tentu tidak akurat sehingga sampai saat ini gagal panen akibat penyakit kopi masih terus terjadi. Oleh sebab itu diperlukan sistem modernisasi pertanian untuk mendeteksi penyakit pada tanaman kopi untuk memperoleh hasil panen yang berkualitas dan mengefisienkan sistem pertanian saat ini.

Teknologi saat ini sudah memunculkan berbagai kemudahan salah satunya sistem yang disebut dengan artificial intelligence. Artificial Intelligence atau kecerdasan buatan adalah sistem komputer yang mampu melakukan tugas-tugas yang biasanya membutuhkan kecerdasan manusia. Teknologi ini dapat membuat keputusan dengan cara menganalisis dan menggunakan data yang tersedia di dalam sistem (Lubis, 2021), dengan sistem ini dapat direncanakan sebuah alat untuk mendeteksi penyakit pada pertanian dengan memprogramnya untuk mengenali berbagai penyakit pada pertanian. Oleh sebab itu penulis memiliki gagasan untuk merancang grafik user interface (GUI) yang merupakan aplikasi berbasis artificial intelligence untuk mendeteksi penyakit pada tanaman kopi. Alat ini dirancang untuk dapat mendeteksi kondisi normal kopi dan 4 penyakit tanaman kopi yang paling umum dan menyebabkan dampak besar bagi kegagalan panen hingga saat ini, 4 penyakit tanaman kopi tersebut yaitu Cercospora, Leaf Rust, Miner dan Phoma. Sistem artificial intelligence ini nantinya akan diintegrasikan dengan aplikasi android yang cukup umum dan mudah untuk diakses oleh para petani mengingat penggunaan android sudah merambah ke seluruh kalangan termasuk para petani saat ini. Inovasi ini diharapkan dapat memberikan kemudahan bagi para petani muda dalam kegiatan pengecekan tanaman kopi sehingga jumlah gagal panen dapat diminimalisir serta akan terjadi peningkatan hasil pertanian kopi di Indonesia.

Convolutional Neural Network


Convolutional Neural Network (CNN) merupakan arsitektur jaringan untuk pembelajaran mendalam yang belajar langsung dari data, dengan menghilangkan kebutuhan untuk melakukan ekstraksi fitur secara manual (Pathak, et al., 2018). CNN selain untuk klasifikasi juga bisa digunakan untuk mendeteksi dan mengenali object pada sebuah gambar. Convolutional Neural Network adalah algoritma pembelajaran mendalam yang populer, umumnya digunakan untuk menganalisis *intra* seperti pengenalan objek, klasifikasi objek, dan banyak lagi bidang-bidang lainnya (O'shea, 2015). Pada gambar 1 dijelaskan bagaimana cara kerja dari Convolutional Neural Network.



Gambar 1. Arsitektur CNN Transfer Learning

Transfer Learning adalah metode pembelajaran mendalam (Alom, et al., 2018) di mana model yang telah dilatih sebelumnya digunakan kembali. Ide dasar pembelajaran transfer ditunjukkan pada gambar 2. Intinya adalah menggunakan model yang telah dilatih sebelumnya yang relatif kompleks dan berhasil, dilatih dari sejumlah besar sumber data, misalnya ImageNet, dan kemudian “mentransfer” pengetahuan yang dipelajari ke tugas yang relatif sederhana dengan sejumlah kecil data.

Tiga atribut penting untuk membantu transfer: (i) Keberhasilan model yang telah dilatih sebelumnya membantu pengguna menghilangkan penyetelan hyperparameter; (ii) Lapisan awal dalam model yang telah dilatih sebelumnya dapat dianggap sebagai ekstraktor fitur yang membantu mengekstraksi fitur tingkat rendah, seperti tepian, rona, gumpalan, corak, dan tekstur; (iii) Model target mungkin hanya perlu melatih ulang beberapa lapisan terakhir dari model yang telah dilatih sebelumnya, karena kami yakin beberapa lapisan terakhir melaksanakan tugas identifikasi yang kompleks.



Gambar 2. Ide dari transfer learning

DenseNet201

Pengenalan tradisional CNN dapat ditemukan di (Ying, et al., 2018). Namun, dalam CNN tradisional, semua lapisan terhubung secara bertahap seperti pada persamaan-1, yang membuat jaringan sulit untuk masuk lebih dalam dan lebih luas, karena mungkin akan menghadapi masalah ledakan atau hilangnya gradien.

Kemudian, ResNet menawarkan ide untuk menggunakan koneksi pintasan dengan melewati setidaknya dua lapisan. Gambar 3 menunjukkan strukturnya, yang masukannya adalah x_{l-1} dan keluaran setelah dua lapisan konvolusi $H_l(x_{l-1})$ ditambahkan dengan pintasan ke lapisan masukan x_{l-1} , sehingga penjumlahannya adalah keluaran dari lapisan ke-l, seperti yang diungkapkan pada persamaan-2.


Kemudian, DenseNet merevisi model lebih lanjut dengan menggabungkan semua peta fitur secara berurutan, bukan menjumlahkan peta fitur keluaran dari semua lapisan sebelumnya seperti yang diungkapkan dalam persamaan-3

$$x_l = H_l(x_{l-1}) \tag{1}$$

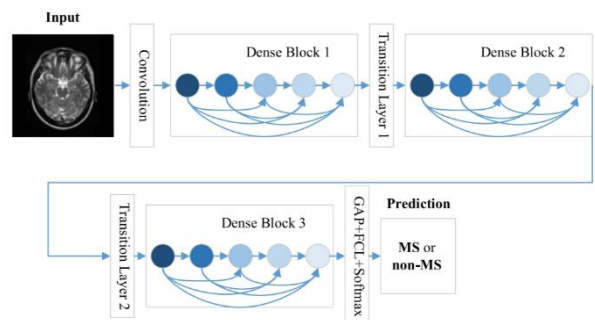
$$x_l = H_l(x_{l-1}) + x_{l-1} \tag{2}$$

$$x_l = H_l([x_0, x_1, x_2, \dots, x_{l-1}]) \tag{3}$$

dimana, l berarti indeks lapisan dan H berarti operasi non-linier. x_l mewakili fitur lapisan ke-l.



Gambar 3. Struktur Blok Dense (Lapisan pertama memiliki peta fitur k_0 , lapisan kedua memiliki peta fitur k_0+k , dan lapisan terakhir memiliki peta fitur k_0+4k).




Gambar 4. Hubungan Blok Dense dan Lapisan Transisi (GAP = global average pooling; FCL = fully connected layer; MS = multiple sclerosis)

Dengan mempertimbangkan Persamaan-3, DenseNet menawarkan rangkaian semua peta fitur dari lapisan sebelumnya, yang berarti, semua peta fitur disebarkan ke lapisan berikutnya dan terhubung ke peta fitur yang baru dibuat. DenseNet yang baru dikembangkan memperkenalkan beberapa keunggulan seperti

penggunaan kembali fitur dan mengurangi masalah ledakan atau hilangnya gradien. Namun, agar struktur DenseNet layak, perubahan berikut harus dilakukan, termasuk pengambilan sampel peta fitur untuk memungkinkan penggabungan. Jika ukuran peta fitur terus berubah, maka operasi penggabungan tidak mungkin dilaksanakan. Kemudian, ide blok padat diajukan untuk mewujudkan down-sampling. Di antara blok padat terdapat lapisan transisi, yang meliputi operasi: normalisasi batch, konvolusi, dan operasi pengumpulan seperti yang ditunjukkan pada gambar 5. Sementara itu, kami menawarkan gambar 5 untuk mengilustrasikan kasus blok padat, di mana nomor lapisannya adalah 5 dan tingkat pertumbuhan ditetapkan sebagai k . Setiap lapisan menerima peta fitur dari semua lapisan sebelumnya.

Dari gambar 5, kita dapat menemukan bahwa k peta fitur dihasilkan untuk setiap operasi H_1 . Karena ada lima lapisan pada gambar 5, kita bisa mendapatkan peta fitur $k_0 + 4k$. k_0 adalah jumlah peta fitur dari lapisan sebelumnya. Nilai default k pada penelitian ini adalah 32.



Gambar 5. Model DenseNet

Jenis Penyakit Tanaman kopi Pada Citra daun

1. Rust (Karat Daun)

Ahli patologi dan peneliti melakukan tur keliling perkebunan kopi, Ahli patologi mengidentifikasi karat daun kopi dengan mengamati daun yang bercak kecil berwarna kuning-oranye dan berbentuk tepung. Ahli patologi memeriksa daun yang terdapat bercak klorotik pada permukaan atas dan bintil karat pada permukaan bawah daun. Gambar daun tersebut diambil dan kemudian diberi label Rust. Ahli patologi menjelaskan, karat/Rust disebabkan oleh *hemileia broadatrix* dan menyebar ke bagian bawah daun melalui angin dan air hujan. Setelah diidentifikasi, gambar daun yang terserang diambil menggunakan kamera digital. Sebanyak 8337 gambar diambil dan diproses di kelas ini. Gambar dibawah ini menunjukkan gambar daun yang terkena karat.



Gambar 6. Gambar daun yang terkena Karat Daun Kopi

2. Phoma (Hawar Daun)

Peneliti bersama ahli patologi tanaman berpindah-pindah lahan dan menggunakan metode observasi untuk mengidentifikasi daun yang pohonnya mulai mati dari ujung daun. Menurut ahli patologi, daun yang mati dari ujung ke arah sisi yang lain merupakan indikasi kuat bahwa daun tersebut menderita foma. Daun-daun tersebut diidentifikasi dan gambarnya diambil menggunakan kamera digital untuk diproses lebih lanjut. Sebanyak 6572 gambar diambil dan diproses di kelas ini. Gambar di bawah menunjukkan gambar daun yang terserang Phoma.



Gambar 7. Gambar daun yang terkena Phoma

3. Miner (Pengorok Daun)

Selama masa makan larva penambang menurut ahli patologi, terdapat bekas kuning yang tertinggal di bawah epidermis daun kopi. Dengan uraian tersebut, ahli patologi tanaman menelusuri seluruh perkebunan kopi dan menggunakan observasi untuk mengidentifikasi daun yang terserang. Daun yang teridentifikasi difoto menggunakan kamera digital dan disimpan untuk diproses lebih lanjut. 16.979 gambar dikumpulkan dan diproses untuk kelas ini. Gambar di bawah menunjukkan gambar daun yang terkena Miner.



Gambar 8. Gambar daun yang terkena Miner

4. Cescospora (Bercak Daun)

Metode observasi digunakan untuk mengidentifikasi penyakit ini pada daun kopi. Menurut ahli patologi, munculnya bintik-bintik abu-abu melingkar dengan bagian tengah berwarna coklat atau putih merupakan indikasi kuat adanya Cescospora. Dengan adanya gambaran tersebut, para peneliti bersama dengan ahli patologi melakukan tur ke seluruh ladang kopi untuk mengidentifikasi daun-daun tersebut dan mengambil gambarnya menggunakan kamera digital mengikuti metode yang digunakan. Sebanyak 7682 dikumpulkan dan diproses untuk kelas ini. Gambar di bawah menunjukkan gambar daun yang terkena Cescospora.



Gambar 9. Gambar daun yang terkena Cescospora

5. Healthy (Sehat)



Gambar 10. Gambar daun sehat

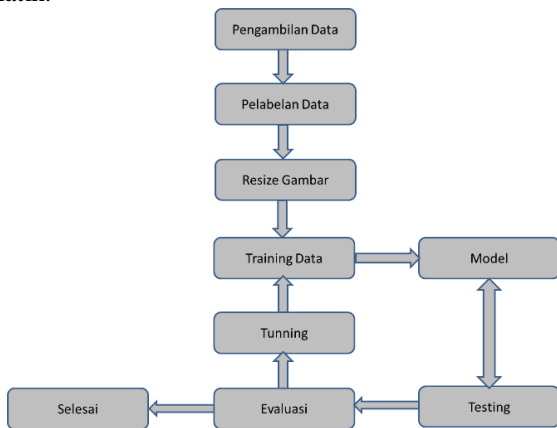
METODE PENELITIAN

Alur dan Kerangka Penelitian

Pada penelitian ini proses perencanaan sampai dengan penelitian ini selesai memiliki beberapa tahapan sesuai dengan Gambar 11.

7. Pengumpulan Data

Penelitian ini pertama menggunakan data sekunder dari Dataset dari Arabica coffee plantation sebagai data training untuk pengujian dari algoritma deep learning yang dirancang. Dataset ini memiliki total 58.555 gambar 46.844 (80%) diantaranya digunakan untuk melatih model. Semua gambar terbagi menjadi 5 kelas yaitu 4 jenis penyakit dan 1 tumbuhan sehat seperti pada tabel 1. Sisanya sebanyak 11.711 (20%) gambar akan digunakan untuk melakukan test model terhadap data yang sudah dilatih.



Gambar 11. Metodologi penelitian

Selanjutnya pengambilan data primer secara langsung menggunakan kamera hp dan kamera digital seperti pada tabel 2. Jumlah data yang diambil sebanyak 1000 gambar untuk setiap kelasnya, jadi total 5000 gambar akan digunakan untuk melakukan test model terhadap data yang sudah dilatih. Data diambil dari lapangan menggunakan kamera digital, dan kamera hp, dengan pembagian 80% sebagai data latih (4000 gambar) dan 20% sebagai data uji (1000 gambar).

Tabel 1. Data sekunder dari Dataset Arabica coffee plantation

No	Nama Kelas	Jumlah Gambar
1	Rust (Karat Daun)	8.337
2	Phoma (Hawar Daun)	7.682
3	Miner (Pengorok Daun)	16.979
4	Cescospora (Bercak Daun)	6572
5	Healthy (Sehat)	18.985
Total		58.555

Tabel 2. Data primer pengambilan langsung

No	Nama Kelas	Jumlah Gambar
1	Rust (Karat Daun)	1000
2	Phoma (Hawar Daun)	1000
3	Miner (Pengorok Daun)	1000
4	Cescospora (Bercak Daun)	1000
5	Healthy (Sehat)	1000
Total		5000

2. Pelabelan Data

Pelabelan data adalah proses mengidentifikasi data mentah (gambar, file teks, video, dan lain lain.) serta menambahkan satu atau beberapa label yang bermakna dan informatif untuk memberikan konteks agar model *machine learning* dapat belajar darinya. Misalnya, label mungkin menunjukkan apakah foto berisi burung atau mobil, kata-kata apa yang diucapkan dalam rekaman audio, atau apakah sinar-x berisi tumor. Pelabelan data diperlukan untuk berbagai kasus penggunaan termasuk penglihatan komputer, pemrosesan bahasa alami, dan pengenalan ucapan. Dalam *machine learning*, set data yang dilabeli dengan benar yang Anda gunakan sebagai standar objektif untuk melatih dan menilai model tertentu sering disebut "*ground truth*." Keakuratan model terlatih kita akan tergantung pada keakuratan *ground truth* Anda sehingga sangat penting untuk mengalokasikan waktu dan sumber daya guna memastikan bahwa pelabelan data sangat akurat. Pada penelitian ini untuk memudahkan proses anotasi menggunakan aplikasi khusus anotasi yang bernama labelimg16.

3. Resize Gambar

Resize gambar atau penskalaan merupakan proses mengubah ukuran citra menjadi lebih kecil. Pada proses resize atau penskalaan pada penelitian ini tidak menggunakan metode khusus. Proses untuk melakukan resize pada penelitian ini yaitu dengan cara membandingkan ukuran citra dari segmentasi dengan target ukuran citra.

4. Training Data

Proses training atau dikenal sebagai dataset pelatihan, set pembelajaran dan set pelatihan, merupakan bagian dalam kumpulan dataset yang disediakan untuk menjadi bahan pembelajaran model agar model dapat menggeneralisasi (menemukan pola) data sehingga nantinya dapat digunakan untuk memprediksi data baru. Penelitian ini semua citra akan diubah ukurannya menjadi 128x128 piksel.

5. Model dan Testing

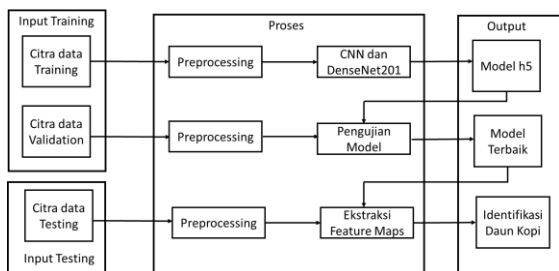
Dari hasil proses simulasi training data dengan memberikan parameter yang terbaik akan didapatkan model jaringan terlatih yang akan digunakan untuk menguji data uji/testing.

6. Evaluasi Model

Evaluasi model ini digunakan untuk mengukur ketepatan atau jumlah error yang ada pada model yang sudah kita bangun. Hal ini bertujuan agar kita mengetahui seberapa optimal model kita untuk memecahkan suatu permasalahan. Selain itu disini kita bisa menguji kehandalan dataset yang kita punya. Apakah dataset tersebut relevan dan handal untuk diekstrak pengetahuannya. Dalam evaluasi object detection standar yang biasa digunakan adalah MSE (mean square error).

7. Perancangan Model CNN dan DenseNet201

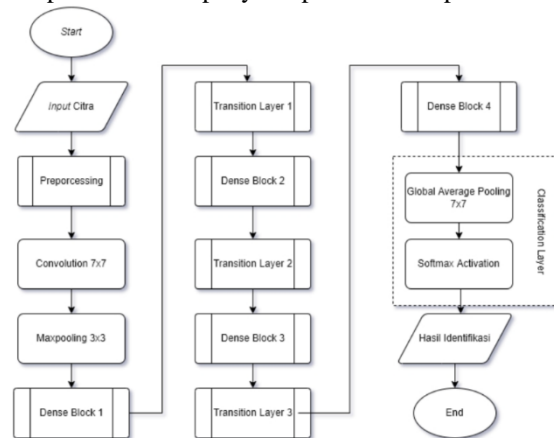
Pada penelitian ini terdapat beberapa tahapan untuk mendeteksi penyakit daun kentang yang didasarkan pada beberapa penelitian terdahulu. Tahapan secara umum untuk mengidentifikasi penyakit daun kentang ada pada gambar 12.



Gambar 12. Tahapan proses klasifikasi

Input training merupakan bagian pada tahap training

data dengan memasukkan citra data training dan validation ke dalam preprocessing data. Prerprocessing data yang dilakukan antara lain mengubah ukuran citra menjadi 128x128 piksel dan menormalisasi data yang sudah diresize. Pada bagian citra data training terdapat proses classification dan feature extraction yang dilakukan menggunakan model DenseNet201. Operasi umum yang terdapat pada model DenseNet201 yakni batch normalization, ReLU Activation, dan proses convolution. Layer yang terdapat pada model DenseNet201 adalah dense block 1, transition layer 1, dense block 2, transition layer 2, dense block 3, transition layer 3, dense block 4 dan classification layer yang nantinya menghasilkan model yang sudah di training dengan format h5. Pengujian model dilakukan pada data validation proses. Output yang dihasilkan dari proses tersebut adalah model terbaik dalam sisi bobot. Citra data testing akan diubah ukurannya menjadi 128x128 piksel dan dinormalisasikan dengan memasukkannya pada tahap preprocessing. Kemudian akan dilakukan ekstraksi feature maps dengan cara mengambil nilai bobot terbaik dari data training yang nantinya akan menghasilkan output klasifikasi penyakit pada daun kopi arabika.



Gambar 13. Diagram Alir DenseNet201

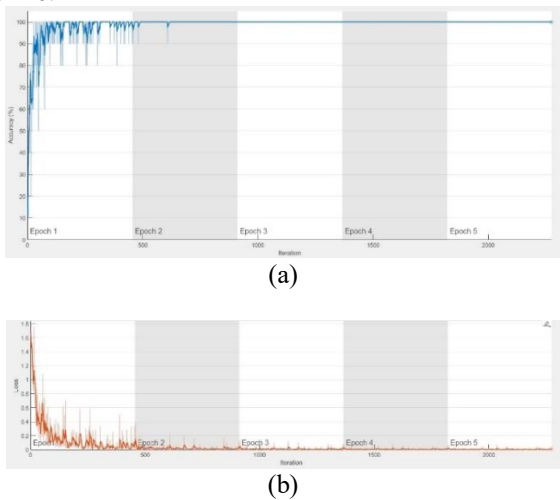
Pada gambar 13 diilustrasikan flowchart algoritma DenseNet201 dalam menentukan identifikasi penyakit daun kopi arabika. Tahapan dari model DenseNet201 dimulai dengan input citra dan preprocessing, lalu dilakukannya operasi convolution 7x7 dengan strides 2. Selanjutnya akan dilakukan proses max pooling 3x3 dengan stides 2 yang nantinya akan mendapatkan nilai matriks, nilai matriks ini akan diproses ke dalam layer dense block 1, transition layer 1, dense block 2, transition layer 2, dense block 3, transition layer 3, dense block 4. Nilai matriks selanjutnya akan diproses ke dalam classification layer dengan operasi global average pooling 7x7 dan kemudian masuk ke dalam softmax activation. Softmax activation merupakan layer terakhir pada model DenseNet201 yang digunakan untuk menentukan kelas klasifikasi.

Hasil Training dan Evaluasi

Algoritma yang digunakan pada penelitian pendeteksi penyakit tanaman pangan ini menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur Alexnet dan Pretrained DenseNet201. Keunggulan dari algoritma CNN ialah pada kemampuannya yang baik dan cepat dalam mendeteksi pola pada suatu gambar.

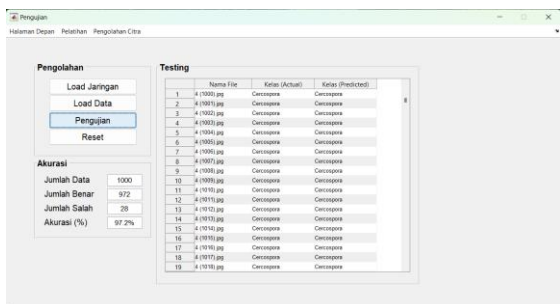
Proses *training* dilakukan dengan melibatkan dua *callbacks* yaitu *early stopping callback* dan *reduce learning rate on plateau callback*. Kedua algoritma CNN ini berperan penting untuk meningkatkan kinerja algoritma pada saat proses training.

Reduce learning rate on plateau callback akan menurunkan *learning rate* sampai ke angka 10^{-5} sehingga algoritma dapat meningkatkan akurasi dan mengurangi loss. *Early stopping callback* berfungsi menghentikan proses *training* jika tidak terjadi peningkatan yang signifikan agar tidak menimbulkan *overfitting*. Grafik peningkatan akurasi dan penurunan loss seiring dengan penambahan epoch/iterasi dapat dilihat pada gambar 14 dan 16.




Gambar 14. (a) Grafik Peningkatan Akurasi dan (b) Penurunan Loss Model DenseNet-201

Model DenseNet-201 memiliki tingkat akurasi dalam mengenali penyakit pada tanaman dengan rata-rata akurasi mencapai 97,2 % dan loss tidak lebih dari 0.22 %.



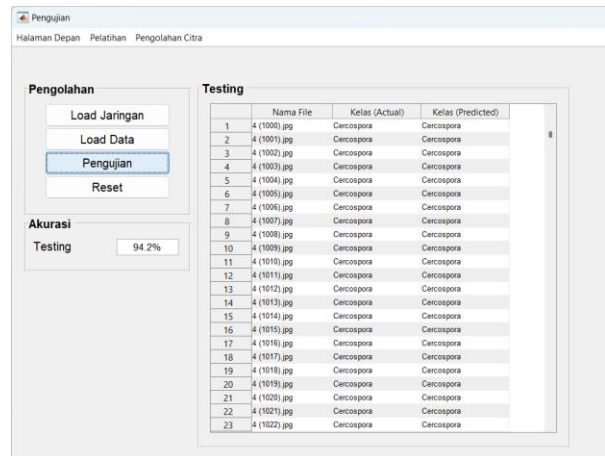
Gambar 15. GUI pengujian data Model DenseNet-201

Pada tampilan GUI pengujian data dari 1000 data uji dengan Model DenseNet-201, ada 972 data yang benar dan 28 data yang salah, akurasi yang didapatkan 97,2%.



Gambar 16. (a) Grafik Peningkatan Akurasi dan (b) Penurunan Loss Model CNN Alexnet

Model CNN Alexnet memiliki tingkat akurasi dalam mengenali penyakit pada tanaman dengan rata-rata akurasi mencapai 94,2 % dan loss tidak lebih dari 0.22 %.



Gambar 17. GUI pengujian data Model CNN Alexnet

Pada tampilan GUI pengujian data dari 1000 data uji dengan Model DenseNet-201, ada 942 data yang benar dan 58 data yang salah, akurasi yang didapatkan 94,2%. Terlihat dari grafik pengujian tingkat akurasi menggunakan Model DenseNet-201 lebih baik dibandingkan Model CNN Alexnet.

UCAPAN TERIMA KASIH

Diucapkan terima kasih kepada Universitas Sriwijaya melalui LPPM yang telah mendanai penelitian ini pada skema Sainteks dengan nomor kontrak 0012/UN9/SK.LP2M.PT/2024.

DAFTAR PUSTAKA

- Alom MZ, Taha TM, Yakopcic C, Westberg S, Sidike P, Nasrin MS, et al. The history began from alexnet: A comprehensive survey on deep learning approaches. 2018.
- Arvianti EY, Masyhuri M, Waluyati LR, Darwanto DHJA. Gambaran krisis petani muda Indonesia. 2019;8(2):168-80.
- Faizin A, Maghfiroh CNJA. Pengaruh rorak terhadap serangan hama pada tanaman kopi Robusta (*Coffea robusta* L.). 2023;5(2):54-67.
- Fatchurrachman A, Udjulawa DJJA. Identifikasi Penyakit Pada Tanaman Kopi Berdasarkan Citra Daun Menggunakan Metode Convolution Neural Network. 2023;3(2):151-9-9.
- Girshick R, Donahue J, Darrell T, Malik JJItopa, intelligence m. Region-based convolutional networks for accurate object detection and segmentation. 2015;38(1):142-58.
- Irfansyah D, Mustikasari M, Suroso AJJIPI. Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi. 2021;6(2):87-92.
- Jatmoko C, Sinaga D, editors. Metode K-Nearest Neighbor dan Ekstraksi Fitur GLCM untuk Mengklasifikasikan Biji Kopi Robusta dan Arabika Lokal. Seminar Nasional Teknologi dan Multidisiplin Ilmu (SEMNASTEKMU); 2022.
- Jordan MI, Mitchell TMJS. Machine learning: Trends, perspectives, and prospects. 2015;349(6245):255-60.
- Juswadi J, Sumarna PJPJIP. Produktivitas Tenaga Kerja Sektor Pertanian dan Korelasinya dengan Usia Petani di Jawa Barat. 2023;11(2):361-9.
- Krizhevsky A, Sutskever I, Hinton GJAC. ImageNet classification with deep convolutional neural networks (AlexNet) ImageNet classification with deep convolutional neural networks (AlexNet). 2023.
- Lubis MSY, editor Implementasi Artificial Intelligence Pada System Manufaktur Terpadu. Prosiding Seminar Nasional Teknik UISU (SEMNASTEK); 2021.
- Mathieu M, Couprie C, LeCun YJapa. Deep multi-scale video prediction beyond mean square error. 2015.
- Murni S, Widiyanto D, Dewi CNP, editors. Klasifikasi Citra Penyakit Daun Kopi Arabika Menggunakan Support Vector Machine (SVM) dengan Seleksi Fitur Information Gain. Prosiding Seminar Nasional Mahasiswa Bidang Ilmu Komputer dan Aplikasinya; 2022.
- Oberweger M, Wohlhart P, Lepetit VJapa. Hands deep in deep learning for hand pose estimation. 2015.
- O'shea K, Nash RJapa. An introduction to convolutional neural networks. 2015.
- Pathak AR, Pandey M, Rautaray SJPcs. Application of deep learning for object detection. 2018;132:1706-17.
- Purwins H, Li B, Virtanen T, Schlüter J, Chang S-Y, Sainath TJIJoSTiSP. Deep learning for audio signal processing. 2019;13(2):206-19.
- Ren S, He K, Girshick R, Sun JJAinips. Faster r-cnn: Towards real-time object detection with region proposal networks. 2015;28.
- Ruvananda AR, Taufiq MJKJEdM. Analisis faktor-faktor yang mempengaruhi impor beras di Indonesia. 2022;19(2):195-204.
- Shanthi T, Sabeenian RJC, Engineering E. Modified Alexnet architecture for classification of diabetic retinopathy images. 2019;76:56-64.
- Sidharta V. Suatu Kajian Komunikasi Pembangunan Pertanian Indonesia. 2022;2(2):229-32.
- Solichah C, Wicaksono D, Waluya W, Brotodjojo R. Pengendalian Hayati Hama dan Penyakit Tanaman Kopi. 2020.
- Soesanto IL. Kompendium Penyakit-Penyakit Kopi: Penerbit Andi; 2020.
- Thoriq A, Sugandi WK, Sampurno RM, Soleh. Peningkatan Pengetahuan Dan Tindakan Petani Dalam Budi Daya Tanaman Kopi Berbasis Agroforestri. 2020;17(3):209-19.
- Windiawan R, Suharso AJEIJKdATI. Identifikasi penyakit pada daun kopi menggunakan metode deep learning VGG16. 2021;13(2):43-50.
- Wahyuningtyas B, Tritoasmoro II, Ibrahim NJeoE. Identifikasi Penyakit Pada Daun Kopi Menggunakan Metode Local Binary Pattern Dan Random Forest. 2023;9(6).
- Wildah SK, Latif A, Mustopa A, Suharyanto S, Maulana MS, Sasongko AJJ. Klasifikasi Penyakit Daun Kopi Menggunakan Kombinasi Haralick, Color Histogram dan Random Forest. 2023;11(1):36-41.
- Ying W, Zhang Y, Huang J, Yang Q, editors. Transfer learning via learning to transfer. International conference on machine learning; 2018: PMLR.
- Yuliany S, Rachman ANJBI. Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Kopi Menggunakan Metode Convolutional Neural Network (CNN). 2022;13(1):54-65.
- Zhang J, Karkee M, Zhang Q, Zhang X, Yaqoob M, Fu L, et al. Multi-class object detection using faster R-CNN and estimation of shaking locations for automated shake-and-catch apple harvesting. 2020;173:105384.
- Zhu Y, Newsam S, editors. Densenet for dense flow. 2017

IEEE international conference on image processing (ICIP); 2017: IEEE.