

KOMPARASI PENGGUNAAN DATA LAB DAN FIELD CONDITION UNTUK MEMBANGUN MODEL KLASIFIKASI PENYAKIT PADA DAUN APEL

Oki Nurul Abada, Chaerur Rozikin, Riza Ibnu Adam

Informatika, Universitas Singaperbangsa Karawang

HS. Ronggo Waluyo, Puseurjaya, Kec. Telukjambe Timur, Kab. Karawang, Jawa Barat, Indonesia

oki.abada18145@student.unsika.ac.id

ABSTRAK

Produksi buah apel di Indonesia pada tahun 2021 mengalami penurunan sebanyak 6.807 Ton dibandingkan dengan tahun sebelumnya. Salah satu faktor yang berkontribusi dalam penurunan tersebut adalah penyakit yang menyerang tanaman apel. Jika hal tersebut dibiarkan tanpa penanganan dan identifikasi yang tepat, maka dalam kasus terburuknya potensi kegagalan panen dapat mencapai 60%. Tujuan penelitian ini adalah mengimplementasikan teknologi *deep learning* dengan menggunakan arsitektur Mobilenet berbasis *Transfer Learning* untuk melakukan identifikasi penyakit terhadap daun tanaman apel berdasarkan citra gambar yang diolah dengan melakukan komparasi terhadap dataset yang membangunnya. Penelitian ini mengadopsi metode *Machine Learning Modelling Life Cycle* yang berfokus kepada pengembangan model kecerdasan buatan. Tahapannya meliputi *data collection, preprocessing, modelling, evaluation* dan *inference*. Hasil skema uji silang dataset, menunjukkan kinerja lebih baik pada model *field condition* dibandingkan model *lab condition*, dengan akurasi 70,55% dan AUC 0,8872. Berdasarkan temuan tersebut dapat disimpulkan bahwa model yang dibangun menggunakan dataset *field condition* memiliki kinerja lebih unggul dalam menghadapi data baru untuk tugas klasifikasi penyakit pada daun apel.

Kata kunci : Klasifikasi, MobileNet, *Transfer Learning*, Penyakit Daun Apel

1. PENDAHULUAN

Tahun 2021, Indonesia mengalami penurunan produksi sebesar 6.807 Ton dari 516.351 Ton pada tahun 2020 menjadi 509.544 Ton, hal tersebut menjadi kekhawatiran sendiri bagi petani dikarenakan hama dan/atau penyakit yang menyerang tanaman apel menjadi salah faktor yang mempengaruhi kualitas dan tingkat produksi pada tanaman tersebut [1][2]. Studi terbaru menyatakan bahwa permukaan daun memiliki peran penting untuk menilai seberapa parah tingkat serangan penyakit pada tanaman di tingkat daun dan ekstrapolasi karena mempengaruhi proses penting pada tanaman yaitu fotosintesis, yang akhirnya dapat membahayakan pertumbuhan pada tanaman tersebut. Penyakit yang menyerang apel dapat memberikan kerugian yang cukup signifikan terhadap hasil panen tahunan, diperkirakan kerugian yang diterima dapat mencapai 30%-40% dan dalam skenario terburuknya dapat mencapai hingga 60% [3][4].

Identifikasi penyakit yang biasanya dilakukan melalui pengamatan terhadap perubahan bentuk, corak dan warna pada daun tanaman dapat berlangsung cukup lama dan dapat meningkatkan risiko kesalahan identifikasi [5][6]. Teknologi *deep learning* dapat dimanfaatkan dengan mengolah data citra digital dan menjadi solusi alternatif yang efektif untuk memaksimalkan identifikasi dan analisis penyakit tanaman secara otomatis.

Penelitian ini akan menerapkan arsitektur Mobilenet berbasis *transfer learning* untuk pembangunan model. Arsitektur ini diciptakan untuk dapat membuat model kecerdasan buatan dengan ukuran yang kecil, kinerja yang cepat dan ringan serta dapat digunakan pada perangkat dengan beban kerja memori

atau komputasi yang kecil (ringan)[7]. Penerapan MobileNet telah dilakukan oleh beberapa penelitian terdahulu. [8] melakukan penelitian terkait klasifikasi penyakit pada citra daun menggunakan beberapa arsitektur *deep learning* dengan objek daun *olive oil*. Menyatakan bahwa arsitektur MobileNet memiliki keunggulan lebih dibandingkan arsitektur populer lainnya yaitu model yang ringan, komputasi yang cepat dan akurasi yang tinggi dengan nilai akurasi tertinggi sebesar 98,43% menggunakan *optimizer RMSprop*. Penelitian lainnya [9] menerapkan arsitektur MobileNet untuk mengidentifikasi penyakit pada tanaman bunga mawar, mengatur konfigurasi *dense layer*. Hasil yang diperoleh adalah dengan menggunakan teknik *transfer learning*, kinerja model dapat ditingkatkan sampai 9,8%.

Berdasarkan paparan yang telah dikemukakan, diketahui bahwa penerapan *deep learning* dengan arsitektur MobileNet terbukti dapat menjadi salah satu solusi yang efektif dalam mengenali suatu objek dalam masalah klasifikasi citra, khususnya dalam identifikasi penyakit pada tanaman, dengan menggunakan teknik *transfer learning* kinerja model dapat ditingkatkan dengan cukup baik. Namun, penelitian-penelitian tersebut tidak menguji model pada dataset dengan kondisi yang berbeda dengan dataset yang membangun model tersebut. Hal itu mengindikasikan bahwa model hanya dapat bekerja secara baik terhadap data dengan lingkungan yang mirip dengan dataset yang membangunnya. Maka dari itu penelitian ini akan menerapkan pengguna teknik *transfer learning* memakai arsitektur MobileNet sebagai acuan model, dengan membandingkan kinerja model yang dibangun pada dua kondisi data yang berbeda. Harapannya model yang

dibangun dapat mengidentifikasi penyakit pada daun tanaman apel secara baik.

2. TINJAUAN PUSTAKA

2.1. Deep Learning

Deep learning adalah cabang dari *machine learning* yang sepenuhnya didasarkan pada *artificial intelligence* (AI), sebagai *neural network* yang meniru cara kerja dari otak manusia, jadi *deep learning* adalah kamufase dari otak manusia itu sendiri [10]. *Deep learning* dapat bekerja pada dataset yang terlampau besar, menyelesaikan masalah secara *end-to-end*, dan dapat bekerja untuk memetakan pola yang kompleks. *Deep learning* sebagai implementasi dari jaringan syaraf tiruan dengan kumpulan *hidden layer*, terdiri dari banyaknya *neuron* yang dapat mengekstraksi fitur untuk klasifikasi gambar [11].

2.2. MobileNet

Isi dan fitur yang terdapat pada *pre-trained* model MobileNet telah dilatih dengan dataset besar, ImageNet, sebelumnya. Lalu, model akan dialihkan ke *domain* target [12], untuk klasifikasi penyakit pada daun apel. Salah satu keunggulan dari arsitektur ini, adalah dapat mengatasi kebutuhan akan *computing resource* berlebih. Perbedaan mendasar dengan arsitektur lainnya, ada pada penggunaan lapisan atau *layer* konvolusi dengan ketebalan filter yang sesuai dengan ketebalan dari input gambar. MobileNet membagi konvolusi menjadi *depthwise convolution* dan *pointwise convolution* [13]. Tujuan dari pembagian komputasi ini adalah untuk memangkas jumlah parameter secara signifikan, sehingga dibandingkan teknik lainnya dengan kedalaman jaringan serupa, MobileNet menghasilkan model yang lebih ringan dengan hasil yang sangat baik.

2.3. Transfer Learning

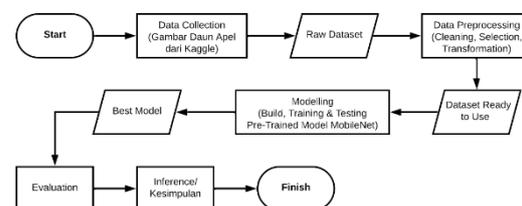
Transfer Learning merupakan teknik yang dapat digunakan untuk mendapatkan atau mentransfer *insights* dan pengetahuan yang terdapat pada model yang telah dilatih/*trained* sebelumnya untuk dapat dimanfaatkan pada model baru yang memiliki tugas yang mirip dengan ruang lingkup penelitian sebelumnya [14]. Teknik ini dapat menjadi solusi ketika dataset baru yang digunakan untuk melatih model jumlahnya sedikit (kecil), juga dapat mengurangi biaya komputasi dan mempercepat proses pelatihan pada saat melakukan implementasi model *deep learning*. Menurut Soria, dkk. (2009) keunggulan dari teknik *transfer learning* adalah pembelajaran model yang dapat berjalan lebih cepat hal itu dapat memangkas waktu komputasi, inisiasi model yang lebih baik karena diawali dengan pengetahuan yang sudah ada sebelumnya dan meningkatnya akurasi setelah proses pelatihan karena diawali inisiasi model yang lebih baik dengan *learning rate* yang lebih tinggi.

2.4. Penyakit Daun Apel

Apel merupakan tanaman buah yang berasal dari Asia barat dengan iklim subtropis, dan menjadi buah yang cukup banyak diminati oleh banyak kalangan masyarakat, karena kaya akan manfaat nutrisi dan rasanya yang enak. Namun apel dalam produksinya, juga tak luput dari serangan penyakit. Terdapat dua jenis penyakit yang akan digunakan sebagai bahan penelitian yaitu *apple scab* dan *apple cedar rust/apple rust*. Parasit obligat *Gymnosporangium juniperi virginianae* merupakan penyebab dari penyakit *apple rust*, bertahan hidup pada tanaman sebagai inangnya dengan gejala bercak-bercak coklat dan membuat daun tanaman menjadi rapuh [16]. Berdasarkan sisi ekonomi penyakit *apple scab* menjadi perhatian dunia karena serangannya yang cukup cepat dan dapat mempengaruhi siklus hidup tanaman. Fungi *Venturia inaequalis* menjadi penyebab dari penyakit *apple scab*, dengan gejala yang terjadi adalah terdapat bercak hijau pada kedua sisi daun dan menjadi hitam keunguan seiring berkembangnya penyakit tersebut [17].

3. METODE PENELITIAN

Penelitian ini mengadaptasi metodologi *Machine Learning Modelling Life Cycle*, yang berfokus pada pengembangan model kecerdasan buatan [18]. Alur penelitiannya dapat dilihat pada gambar 1.



Gambar 1. Alur penelitian

3.1. Data Collection

Pada tahap ini data dikumpulkan dan dianalisis apakah data telah sesuai dengan kebutuhan pengembangan model atau belum. Dataset diperoleh dari situs Kaggle. Dataset yang digunakan sebagai *lab condition* adalah dataset PlantVillage [19]. Sedangkan dataset yang digunakan sebagai *field condition* adalah dataset Plant Pathology [20].

3.2. Data Preprocessing

Dataset diolah dengan cara membersihkan dan menghapus data yang memiliki kualitas buruk, objek tidak jelas dan gambar yang memiliki *noise* berlebih. Selanjutnya data terbaik akan dipilih satu persatu sebagai bentuk dari proses *under sampling* dimana keseluruhan jumlah data dari setiap kelas akan disesuaikan dengan kelas yang memiliki jumlah data terkecil [21], tujuannya agar model tidak cenderung fokus mengenali kelas prediksi yang memiliki jumlah data terbanyak, sehingga bias pada model dapat dikurangi. Setelah itu dilakukan pembagian dataset

menjadi *training*, *validation* dan *testing* dengan rasio pembagian data 70:10:20. Diakhir data *training* akan melewati proses transformasi agar memperbanyak persebaran data hal yang dilakukan adalah penskalaan citra, normalisasi data, dan melakukan augmentasi.

Tabel 1. Hasil data *preprocessing*

Nama Kelas	Lab Condition	Field Condition
Healthy	275	275
Apple_rust	275	275
Apple_scab	275	275
Jumlah	825	825

3.3. Modelling

Tahap ini berupa pembuatan model dimana *pre-trained* model MobileNet di *import* tanpa menyertakan *layer* klasifikasi, melakukan pembekuan *hidden layer*, menambahkan konfigurasi *layer* yang diatur oleh parameter *tuning* pada tabel 2.

Tabel 2. Parameter *tuning*

Skenario	Dense Layer	Dropout	Optimizer
1	512	0,5	Adam, RMSprop, SGD, Nadam, Adadelta, Adamax, Adagrad, Adabelief
2	256	0,5	
3	128	0,5	
4	512	0,25	
5	256	0,25	
6	128	0,25	

Pelatihan model akan dijalankan dengan 100 *epoch* dan *learning rate* sebesar $1e-4$. Dilanjutkan dengan pengujian menggunakan data *testing* yang telah disiapkan dan menentukan model dengan kinerja terbaik dari masing-masing skema kondisi data. Setelah model terbaik diperoleh, proses selanjutnya akan dilakukan skema uji silang dataset, dimana model terbaik *lab condition* akan diujikan pada dataset *field condition* begitupun sebaliknya.

3.4. Evaluation

Evaluasi dilakukan dengan cara menjabarkan serta melakukan analisis hasil yang diperoleh dari tahap pelatihan dan pengujian model. Diakhir akan ditarik kesimpulan berdasarkan hasil analisis yang telah dilakukan pada tahap evaluasi.

4. HASIL DAN PEMBAHASAN

Penelitian ini membahas tentang implementasi model *deep learning* menggunakan arsitektur MobileNet berbasis *transfer learning* dalam mengklasifikasi penyakit pada daun tanaman apel. Dengan menggunakan metodologi *Machine Learning Modeling Life Cycle* seluruh tahapan telah selesai dilaksanakan secara baik dimulai dari tahap *data collection* sampai dengan tahap *evaluation* serta telah berhasil memperoleh model klasifikasi yang memiliki kinerja terbaik dalam melakukan identifikasi terhadap penyakit daun apel yaitu *apple rust* dan *apple scab*.

Dataset yang digunakan dikelompokkan menjadi dua kondisi, yaitu "*Lab Condition*" dan "*Field Condition*". Kategori "*Lab Condition*" mencakup citra daun dengan latar belakang yang stabil, sedangkan kategori "*Field Condition*" mencakup citra daun yang diambil langsung dari kebun apel, dengan latar belakang yang bervariasi dan masih terhubung dengan tangkai daun. Kedua dataset tersebut telah diolah dengan cermat sehingga memiliki jumlah data, kelas, dan ukuran gambar yang seragam. Kedua dataset digunakan untuk mengembangkan model menggunakan arsitektur MobileNet yang dikonfigurasi sesuai dengan parameter *tuning* dari Tabel 2. Tujuan di balik pendekatan ini adalah untuk membandingkan performa model dan mengidentifikasi dataset mana yang memiliki kemampuan lebih unggul dalam membangun model untuk melakukan klasifikasi penyakit pada citra daun apel. Dengan demikian, penelitian ini akan memberikan wawasan tentang apakah performa model lebih baik dengan menggunakan citra daun yang diambil dalam kondisi laboratorium atau dalam kondisi lapangan. Langkah-langkah ini dilakukan dengan tujuan memastikan bahwa analisis yang dilakukan memiliki dasar yang kuat dan dapat memberikan hasil yang dapat diandalkan dalam mengevaluasi efektivitas model klasifikasi penyakit daun apel.

Tabel 3. Rataan nilai AUC tiap *optimizer*

Optimizer	AUC
Adam	0.995610808
RMSprop	0.995119417
SGD	0.918832333
Nadam	0.995509167
Adadelta	0.529774417
Adagrad	0.941495
Adamax	0.99088135
Adabelief	0.993852667

Total model yang dihasilkan berdasarkan gabungan skenario pembagian data dengan skenario parameter *tuning* berjumlah sebanyak 96 model. Dari keseluruhan model tersebut, model yang menerapkan *optimizer* Adadelta mendapatkan predikat *failure* berdasarkan keseluruhan nilai AUC-nya yang berada di bawah nilai 0,60 dengan akurasi rendah yang tak dapat mencapai angka 50% hal tersebut menyatakan bahwa *optimizer* Adadelta tidak memiliki kecocokan dengan model yang dibangun. Begitu pula dengan *optimizer* SGD dan Adagrad yang keseluruhan modelnya tergolong sebagai *fair classification* dan model tersebut mengindikasikan terjadinya *underfitting*, dimana model tidak dapat mempelajari karakteristik dari data yang dilatih. Hasil pelatihan model tersebut memiliki selisih yang cukup jauh antara nilai *training* dan *validation accuracy*, serta selisih antara nilai *training* dan *validation loss*.

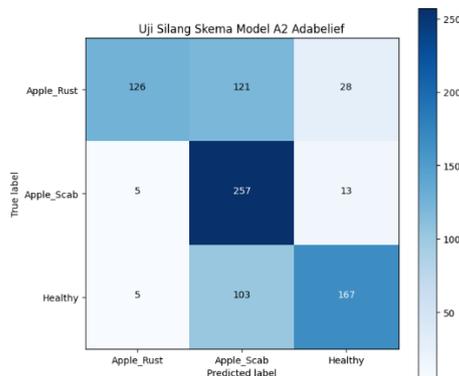
Tabel 4. Akurasi tiap model dengan data *lab condition*

Optimizer	Dense Layer						Rata-rata Akurasi
	Dropout = 0,5			Dropout = 0,25			
	512	256	128	512	256	128	
Adam	0.9702	0.9405	0.9821	0.9405	0.9821	0.9167	0.9554
RMSprop	0.9702	0.9643	0.9583	0.9762	0.9583	0.9524	0.9633
SGD	0.869	0.8274	0.6964	0.744	0.7679	0.8036	0.7847
Nadam	0.9583	0.9643	0.9405	0.9464	0.9286	0.9702	0.9514
Adadelta	0.4702	0.3512	0.3155	0.3274	0.3571	0.3631	0.3641
Adagrad	0.8929	0.8452	0.7619	0.8988	0.8512	0.7857	0.8393
Adamax	0.9524	0.9345	0.9345	0.9702	0.9583	0.9286	0.9464
Adabelief	0.9226	0.9881	0.9702	0.9643	0.9583	0.9762	0.9633
Rata-rata Akurasi	0.8757	0.8519	0.8199	0.846	0.8452	0.8371	0.8459

Tabel 5. Akurasi tiap model dengan dataset *field condition*

Optimizer	Dense Layer						Rata-rata Akurasi
	Dropout = 0,5			Dropout = 0,25			
	512	256	128	512	256	128	
Adam	0.9405	0.9405	0.9405	0.9583	0.9048	0.9286	0.9355
RMSprop	0.9464	0.9167	0.9107	0.9583	0.9643	0.9464	0.9405
SGD	0.8155	0.7321	0.631	0.7738	0.6905	0.6786	0.7202
Nadam	0.9524	0.9167	0.9405	0.9524	0.9405	0.9345	0.9395
Adadelta	0.3333	0.3631	0.3988	0.4821	0.3214	0.3095	0.3681
Adagrad	0.8393	0.7857	0.7798	0.8333	0.7262	0.7381	0.7837
Adamax	0.9167	0.9167	0.8988	0.9345	0.9286	0.8929	0.9147
Adabelief	0.9464	0.875	0.9286	0.9286	0.9345	0.9107	0.9206
Rata-rata Akurasi	0.8363	0.8058	0.8036	0.8527	0.8013	0.7924	0.8154

Sedangkan model yang dibangun dengan *optimizer* Adam, RMSprop, Nadam, Adamax dan Adabelief menghasilkan rata-rata akurasi di atas 90% dan keseluruhan model tergolong *excellent classification* berdasarkan nilai AUC-nya yang berada di atas angka 0,9. Hal tersebut mengindikasikan bahwa model yang dibangun sangat cocok menggunakan ke-5 *optimizer* tersebut. Dengan model terbaik dari masing-masing skenario dataset adalah model yang menggunakan Adabelief dengan konfigurasi *dropout* 0,5 dan *dense layer* 256 untuk dataset *Lab Condition* dan RMSprop dengan konfigurasi *dropout* 0,25 dan *dense layer* 256 untuk dataset *Field Condition*.

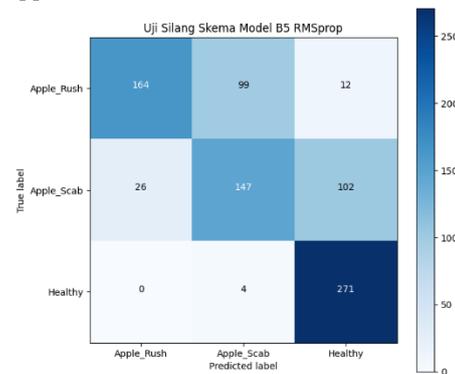


Gambar 2. *Confusion matrix* model *lab condition*

Setelah diperoleh model terbaik selanjutnya kedua model tersebut dilakukan skema uji silang dataset, dimana model yang dibangun menggunakan dataset *Lab Condition* yaitu A2 Adabelief diujikan terhadap dataset *Field Condition* sedangkan model

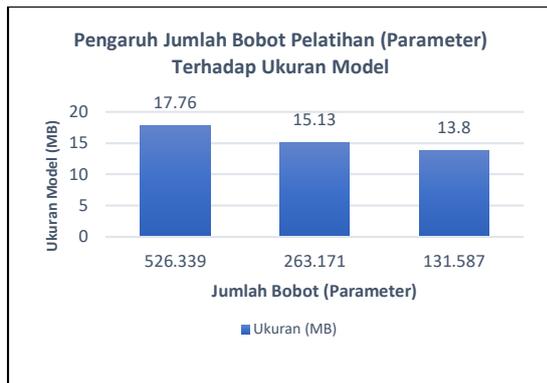
yang dibangun menggunakan dataset *Field Condition* yaitu B5 RMSprop diujikan terhadap dataset *Lab Condition*.

Model A2 Adabelief memiliki akurasi 66,67% dan AUC sebesar 0,9068 meskipun begitu model tersebut memiliki *false positive* yang tinggi pada kelas *apple scab*.



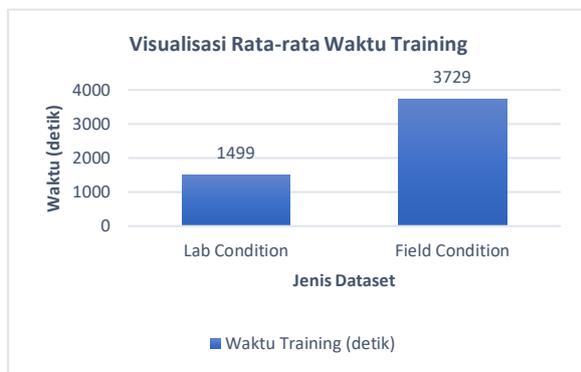
Gambar 3. *Confusion matrix* model *field condition*

Hasil uji silang dataset menunjukkan bahwa model B5 RMSprop memiliki kinerja lebih unggul dibandingkan A2 Adabelief, dengan akurasi sebesar 70,55% dan AUC sebesar 0,8872 dengan *false positive* disetiap kelasnya tidak terlalu berbeda jauh. Berdasarkan hal tersebut dapat diketahui bahwa model yang dibangun menggunakan dataset *field condition* memiliki kinerja yang lebih unggul dibandingkan model yang dibangun menggunakan dataset *lab condition* dalam mengklasifikasi jenis penyakit pada daun apel dan menghadapi data baru.



Gambar 4. Rataan besar ukuran model yang diperoleh

Temuan lainnya yang telah diperoleh adalah ukuran model berbanding lurus dengan banyaknya parameter latih yang didapat dengan mengatur banyaknya *dense layer*.



Gambar 5. Rataan waktu pelatihan model

Berdasarkan grafik di atas, lamanya waktu pelatihan juga dapat dipengaruhi oleh jenis dataset yang digunakan untuk melatih model tersebut, disini dapat diketahui bahwa model yang dilatih menggunakan dataset *field condition* memerlukan waktu pelatihan yang lebih lama dibandingkan model yang dilatih oleh dataset *lab condition*.

5. KESIMPULAN DAN SARAN

Berdasarkan penelitian yang telah selesai dilakukan dapat disimpulkan bahwa model yang dibangun menggunakan dataset *field condition* memiliki kinerja yang lebih optimal dibandingkan model yang dibangun menggunakan dataset *lab condition*. Pada skema uji silang dataset model *field condition* dengan konfigurasi *dense layer* 256, *dropout* 0,25 dan *optimizer* RMSprop mendapat akurasi sebesar 70,55% dan AUC sebesar 0,8872. Sedangkan model *lab condition* dengan konfigurasi *dense layer* 256, *dropout* 0,5 dan *optimizer* Adabelief mendapatkan akurasi sebesar 66,67% dan AUC sebesar 0,9068, model tersebut mendapatkan *false positive* yang tinggi pada kelas *apple_scab*. Konfigurasi parameter *tuning* juga berperan penting dalam pembangunan model, berdasarkan rata-rata akurasi model dengan pengaturan *dense layer* 512 memiliki tingkat kinerja lebih unggul dibandingkan pengaturan lainnya, yang mengartikan bahwa semakin besar nilai

dense layer maka kinerja juga dapat ditingkatkan. Ukuran model juga berbanding lurus dengan pengaturan *dense layer*, semakin besar parameter latih yang diatur dari *dense layer* semakin besar juga ukuran model yang dihasilkan. Temuan selanjutnya dari penelitian ini adalah model yang dilatih menggunakan dataset *field condition* berlangsung lebih lama dengan rata-rata waktu pelatihan adalah 62 menit 9 detik sedangkan rata-rata waktu pelatihan model *lab condition* adalah 24 menit 59 detik. Diharapkan untuk penelitian selanjutnya agar dapat menganalisis pengaruh penggunaan *optimizer* terhadap perbedaan akurasi dan ukuran model yang dihasilkan beserta alasannya.

DAFTAR PUSTAKA

- [1] Badan Pusat Statistik, “Produksi Tanaman Buah-buahan 1997 - 2021,” *Badan Pusat Statistik*, 2021. <https://www.bps.go.id/> (diakses Nov 19, 2022).
- [2] D. Husen, Kusriani, dan Kusnawi, “Deteksi Hama Pada Daun Apel Menggunakan Algoritma Convolutional Neural Network,” *J. Media Inform. Budidarma*, vol. 6, hal. 2103–2110, 2022, doi: 10.30865/mib.v6i4.4667.
- [3] J. Köhl *et al.*, “Dynamics of post-harvest pathogens *Neofabraea* spp. and *Cadophora* spp. in plant residues in Dutch apple and pear orchards,” *Plant Pathol.*, vol. 67, hal. 1264–1277, 2018, doi: 10.1111/ppa.12854.
- [4] M. Naets *et al.*, “To disinfect or not to disinfect in postharvest research on the fungal decay of apple?,” *Int. J. Food Microbiol.*, vol. 266, hal. 190–199, 2018, doi: 10.1016/j.ijfoodmicro.2017.12.003.
- [5] C. Bi, J. Wang, Y. Duan, B. Fu, J. R. Kang, dan Y. Shi, “MobileNet Based Apple Leaf Diseases Identification,” *Mob. Networks Appl.*, 2020, doi: 10.1007/s11036-020-01640-1.
- [6] M. Sardogan, A. Tuncer, dan Y. Ozen, “Plant Leaf Disease Detection and Classification Based on CNN with LVQ Algorithm,” *IEEE 2018 3rd Int. Conf. Comput. Sci. Eng.*, hal. 382–385, 2018, doi: 10.1109/UBMK.2018.8566635.
- [7] A. G. Howard *et al.*, “MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications,” *arXiv*, vol. 1704.04861, 2017, [Daring]. Tersedia pada: <https://www.researchgate.net/publication/316184205>.
- [8] H. Younis, M. Z. Khan, M. U. G. Khan, dan H. Mukhtar, “Robust Optimization of MobileNet for Plant Disease Classification with Fine Tuned Parameters,” *2021 Int. Conf. Artif. Intell. ICAI 2021*, hal. 146–151, 2021, doi: 10.1109/ICAI52203.2021.9445261.
- [9] A. Rajbongshi, T. Sarker, M. M. Ahamad, dan M. M. Rahman, “Rose Diseases Recognition using MobileNet,” *4th Int. Symp. Multidiscip. Stud. Innov. Technol. ISMSIT 2020 - Proc.*, 2020, doi:

- 10.1109/ISMSIT50672.2020.9254420.
- [10] R. M. Cichy dan D. Kaiser, "Deep Neural Networks as Scientific Models," *Trends Cogn. Sci.*, vol. 23, no. 4, hal. 305–317, 2019, doi: 10.1016/j.tics.2019.01.009.
- [11] R. Chauhan, K. K. Ghanshala, dan R. C. Joshi, "Convolutional Neural Network (CNN) for Image Detection and Recognition," *ICSCCC 2018 - 1st Int. Conf. Secur. Cyber Comput. Commun.*, hal. 278–282, 2018, doi: 10.1109/ICSCCC.2018.8703316.
- [12] H. Pan, Z. Pang, Y. Wang, Y. Wang, dan L. Chen, "A New Image Recognition and Classification Method Combining Transfer Learning Algorithm and MobileNet Model for Welding Defects," *IEEE Access*, vol. 8, hal. 119951–119960, 2020, doi: 10.1109/ACCESS.2020.3005450.
- [13] A. Pujara, "Image Classification with MobileNet," *Analytics Vidhya*, 2020. <https://medium.com/analytics-vidhya/image-classification-with-mobilenet-cc6fbb2cd470#> (diakses Des 03, 2022).
- [14] C. Dilmegani, "Transfer Learning in 2022: What it is & How it works," *AI Multiple*, 2022. <https://research.aimultiple.com/transfer-learning/> (diakses Des 06, 2022).
- [15] E. Soria, J. D. M. Guerrero, M. Martinez, R. Magdalena, dan A. J. Serrano, *Handbook Of Research On Machine Learning Applications and Trends: Algorithms, Methods and Techniques*, 1st ed. Information Science Reference, 2009.
- [16] I. R. Sastrahidayat, *Penyakit Tumbuhan oleh Parasit Obligat*. Universitas Brawijaya Press, 2016.
- [17] J. K. Bowen, C. H. Mewsarich, V. G. M. Bus, R. M. Beresford, K. M. Plummer, dan M. D. Templeton, "Venturia Inaequalis: The Causal Agent of Apple Scab," *Mol. Plant Pathology*, vol. 12, no. 2, hal. 105–122, 2011, doi: 10.1111/J.1364-3703.2010.00656.X.
- [18] O. Spjuth, J. Frid, dan A. Hellander, "The machine learning life cycle and the cloud: implications for drug discovery," *Expert Opin. Drug Discov.*, vol. 16, no. 9, hal. 1071–1079, 2021, doi: 10.1080/17460441.2021.1932812.
- [19] D. P. Hughes dan M. Salathe, "An open access repository of images on plant health to enable the development of mobile disease diagnostics," 2015, [Daring]. Tersedia pada: <http://arxiv.org/abs/1511.08060>.
- [20] R. Thapa, K. Zhang, N. Snavely, S. Belongie, dan A. Khan, "The Plant Pathology Challenge 2020 data set to classify foliar disease of apples," *Appl. Plant Sci.*, vol. 8, no. 9, hal. 1–8, 2020, doi: 10.1002/aps3.11390.
- [21] M. O. Ojo dan A. Zahid, "Improving Deep Learning Classifiers Performance via Preprocessing and Class Imbalance Approaches in a Plant Disease Detection Pipeline," *Agronomy*, vol. 13, no. 3, 2023, doi: 10.3390/agronomy13030887.