

PENERAPAN METODE *RESIDUAL NETWORK* (RESNET) DALAM KLASIFIKASI PENYAKIT PADA DAUN GANDUM

Andreanov Ridhovan¹⁾, Aries Suharso²⁾

^{1, 2)} Fakultas Ilmu Komputer , Universitas Singaperbangsa Karawang

Jl. HS.Ronggo Waluyo, Telukjambe Timur, Kabupaten Karawang,

e-mail: andreanov.ridhovan18011@student.unsika.ac.id¹⁾, aries.suharso@staff.unsika.ac.id²⁾

ABSTRAK

Gandum adalah jenis tanaman yang kaya karbohidrat. Permintaan gandum di Indonesia selalu meningkat setiap tahun tetapi berbanding terbalik dengan jumlah produksi gandum nasional. Salah satu faktor yang menghambat produksi gandum adalah kegagalan panen akibat penyakit atau hama. Penyakit yang umum pada tanaman gandum adalah Septoria dan Stripe Rust. Penyakit tersebut dapat diidentifikasi melalui warna dan bercak daun. Seiring perkembangan teknologi, petani dapat mengawasi tanaman secara otomatis menggunakan bantuan komputer. Dengan menggunakan deep learning, penyakit pada tanaman gandum dapat diidentifikasi dengan mudah. Penelitian ini bertujuan untuk mengidentifikasi penyakit pada tanaman gandum melalui daun menggunakan metode Residual Network (ResNet). ResNet adalah jenis arsitektur Convolution Neural Network (CNN) dengan menggunakan model yang sudah dilatih sebelumnya. Dengan ResNet tidak memerlukan untuk melatih data dari awal sehingga dapat mempersingkat waktu. Data yang digunakan terdiri dari 291 gambar yang terbagi menjadi normal, penyakit Septoria, dan penyakit Stripe Rust. Setelah pengujian didapatkan akurasi sebesar 98% dengan perbandingan data latih dan uji sebesar 90:10 dan nilai confusion matrix sebesar 0.35 sehingga dapat disimpulkan bahwa metode ResNet dapat mengidentifikasi penyakit pada tanaman gandum.

Kata Kunci: CNN, Deep learning, Klasifikasi Gambar, ResNet.

ABSTRACT

Wheat is a type of plant that is rich in carbohydrates. The demand for wheat in Indonesia always increases every year but is inversely proportional to the amount of national wheat production. One of the factors that hinder wheat production is crop failure due to disease or pests. Common diseases in wheat plants are Septoria and Stripe Rust. The disease can be identified by color and leaf spot. As technology develops, farmers can monitor crops automatically using the help of computers. By using deep learning, diseases in wheat can be identified easily. This study aims to identify diseases in wheat plants through leaves using the Residual Network (ResNet) method. ResNet is a type of Convolution Neural Network (CNN) architecture using a pre-trained model. With ResNet there is no need to train data from scratch so it can save time. The data used consisted of 291 images which were divided into normal, Septoria disease, and Stripe Rust disease. After testing, it was obtained an accuracy of 98% with a comparison of training and testing data of 90:10 and a confusion matrix value of 0.35 so it can be concluded that the ResNet method can identify diseases in wheat plants.

Keywords: CNN, Deep learning, Image Classification, ResNet.

I. PENDAHULUAN

DALAM Memenuhi sumber energi utama pada tubuh, manusia perlu mengonsumsi karbohidrat. Selain mengonsumsi nasi untuk memenuhi kebutuhan karbohidrat, masyarakat Indonesia juga mengonsumsi gandum sebagai bahan pokok atau bahan olah lainnya. Gandum merupakan tanaman famili *Graminae* (*Poaceae*) yang mengandung lebih banyak protein dibandingkan dengan beras. Mayoritas masyarakat Indonesia mengonsumsi gandum sebagai bahan olahan seperti roti, sereal, dan bahan olahan lainnya sehingga kebutuhan gandum di Indonesia sangat tinggi. Penelitian terbaru terhadap produksi gandum oleh Organisasi Pangan dan Pertanian Perserikatan Bangsa-Bangsa menunjukkan bahwa pasokan gandum saat ini cukup untuk permintaan global. Namun demikian, produksi di masa depan harus meningkat karena populasi global diperkirakan melebihi sembilan miliar orang pada tahun 2050 [1].

Pada tahun 2019, Badan Pusat Statistik menyatakan bahwa konsumsi gandum penduduk Indonesia mencapai 10,69 juta ton atau naik sekitar 5 juta ton dari tahun sebelumnya [2]. Permintaan yang tinggi terhadap gandum membuat pemerintah harus melakukan impor dari negara lain untuk memenuhi permintaan dalam negeri. Produksi gandum dalam negeri masih tergolong cukup minim sehingga tidak mampu memenuhi kebutuhan nasional. Selain faktor alam, penyakit atau hama yang menyerang tanaman gandum menjadi faktor penentu produksi gandum di Indonesia.

Penyakit yang menyerang tanaman gandum berasal dari berbagai faktor seperti kelembaban udara, perubahan

iklim, dan daya tahan yang dimiliki tanaman gandum tersebut. Secara garis besar terdapat dua penyakit atau hama yang terpapar pada tanaman gandum yaitu *Septoria* dan *Stripe Rust*.

Septoria adalah penyakit jamur pada gandum (*Triticum aestivum*), tanaman utama yang menopang ketahanan pangan global. Gejalanya adalah klorosis dan nekrosis jaringan daun gandum serta perubahan warna dan nekrosis pada glume, yang disebut sebagai bercak daun dan noda *glume* [3]. *Stripe Rust* adalah salah satu penyakit gandum utama di seluruh dunia, yang memiliki efek merugikan yang signifikan pada hasil dan kualitas gandum, yang merupakan ancaman serius terhadap ketahanan pangan. Tingkat keparahan penyakit memainkan peran penting dalam manajemen penyakit *Stripe Rust* termasuk pemuliaan varietas gandum tahan penyakit [4]. Penyakit tersebut dapat diidentifikasi melalui perubahan warna dan corak pada daun tanaman gandum. Namun para petani gandum kesulitan dalam membedakan kedua penyakit sehingga dibutuhkan bantuan kecerdasan buatan untuk mendeteksinya.

Seiring perkembangan teknologi yang ada saat ini, komputer atau mesin dapat dirancang untuk melakukan prediksi terhadap suatu objek atau yang lebih dikenal dengan *deep learning*. *Deep learning* adalah model komputasi dari beberapa lapisan pemrosesan untuk mempelajari dan mewakili data dengan berbagai tingkat abstraksi yang meniru bagaimana otak memahami dan memahami informasi multimodal, sehingga secara implisit menangkap struktur rumit dari data skala besar [5]. *Deep learning* telah terbukti menjadi teknologi canggih untuk analisis data besar dengan sejumlah besar kasus yang berhasil dalam pemrosesan gambar, pengenalan ucapan, deteksi objek, dan sebagainya. Baru-baru ini, itu juga telah diperkenalkan dalam ilmu dan teknik pangan [6]. Teknik *deep learning* telah meningkatkan kemampuan untuk mengklasifikasikan, mengenali, mendeteksi, dan mendeskripsikan – dalam satu kata, memahami. Banyak daya komputasi diperlukan untuk memecahkan masalah machine learning karena sifat iteratif dari algoritma *deep learning*, kompleksitasnya seiring dengan meningkatnya jumlah lapisan, dan volume data yang besar yang dibutuhkan untuk melatih jaringan. Sifat dinamis dari metode pembelajaran mendalam – kemampuannya untuk terus meningkatkan dan beradaptasi dengan perubahan dalam pola informasi yang mendasarinya menghadirkan peluang besar untuk memperkenalkan perilaku yang lebih dinamis ke dalam analitik.

Penelitian ini bertujuan untuk mendeteksi penyakit pada tanaman gandum melalui citra gambar daun secara jelas dan akurat menggunakan *deep learning* dengan model ResNet yang diharapkan dapat menghasilkan akurasi dan evaluasi model yang baik. ResNet merupakan *pre trained model* atau model yang telah dilatih sebelumnya sehingga tidak memerlukan konfigurasi khusus untuk mengatur *layer* di dalamnya. Prinsip kerja ResNet adalah membangun jaringan yang lebih dalam dibandingkan dengan jaringan biasa lainnya dan secara bersamaan menemukan jumlah lapisan yang dioptimalkan untuk meniadakan masalah gradien yang hilang. Adapun manfaat dari penelitian ini adalah mengetahui seberapa akurat metode ResNet dalam melakukan deteksi penyakit pada tanaman gandum dan menjadi referensi bagi pembaca untuk melakukan penelitian yang berkaitan dengan klasifikasi gambar menggunakan metode ResNet.

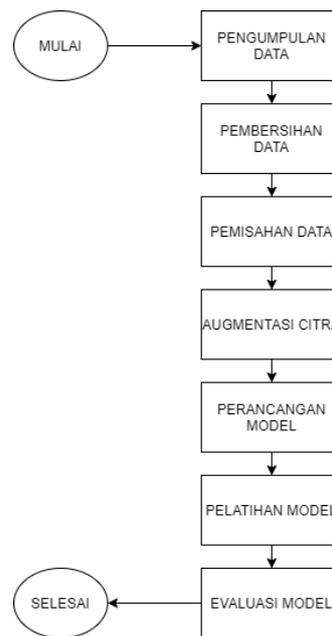
Penelitian sebelumnya membahas tentang penggunaan *deep learning* dapat memberikan akurasi yang tinggi dalam klasifikasi objek [7]. Akurasi dapat ditingkatkan dengan menggunakan teknik augmentasi data yang berfungsi untuk memperbanyak dataset melalui perubahan pada gambar tersebut. Selain itu, proses pelatihan model akan semakin baik jika menerapkan *learning rate* yang tepat.

Penelitian [8] membahas tentang deteksi objek hewan kucing dengan menggunakan metode Mobilenetv1 dan ResNet. Hasil penelitian [8] adalah metode Mobilenetv1 memiliki akurasi rata – rata 99,6% dan ResNet memiliki akurasi 100%. Kedua metode tersebut sama – sama memiliki kesalahan tiga gambar.

Hasil penelitian [9] terhadap deteksi penyakit Covid-19 menggunakan *Residual Network* (ResNet) menghasilkan akurasi yang tinggi dan evaluasi matrik yang baik walaupun data yang digunakan sedikit. Dengan akurasi yang tinggi dan hasil evaluasi matrik yang baik maka model tersebut dapat dipertimbangkan untuk diverifikasi sehingga bisa digunakan untuk mendeteksi penyakit Covid-19 [9].

II. METODE

Penelitian ini dimulai dengan studi literatur yang terkait kemudian dilanjutkan dengan pengumpulan data yang akan digunakan untuk membuat model *deep learning*. Selanjutnya data tersebut akan dilakukan pembersihan data dan pemisahan menjadi data latih dan data uji. Setelah itu digunakan augmentasi citra untuk memperbanyak gambar. Tahapan selanjutnya adalah perancangan dan pelatihan model yang akan digunakan. Pada tahap terakhir dilakukan evaluasi terhadap model yang sudah dilatih. Tahapan penelitian ditunjukkan pada gambar 1.



Gambar 1. Tahapan Metodologi Penelitian.

A. Pengumpulan Data

Gambar yang digunakan pada penelitian ini bersifat publik dan diambil dari Kaggle dengan total 407 gambar yang terbagi menjadi kategori sehat, penyakit *Septoria*, dan penyakit *Stripe Rust* [10]. Persebaran data pada tiap kategori yaitu 102 gambar daun gandum sehat, 97 gambar daun gandum yang terinfeksi penyakit *Septoria*, dan 208 gambar daun gandum yang terinfeksi penyakit *Stripe Rust*. Kamera yang digunakan adalah Canon EOS 5D Mark III yang merupakan kamera digital beresolusi tinggi yang mampu menampilkan detail daun dan lokasi pengambilan data berada di Holeta *wheat farm*, Ethiopia [10]. Gambar daun yang sehat, terinfeksi *Septoria*, dan terinfeksi *Stripe Rust* ditunjukkan pada gambar 2.



Gambar 2. Gambar Daun Gandum a) Sehat, b) Terinfeksi Septoria, c) Terinfeksi Stripe Rust

B. Pembersihan Data

Persebaran data yang tidak merata pada setiap kategori dapat menimbulkan terjadinya kesalahan dalam melakukan klasifikasi objek. Hal tersebut dapat diatasi dengan mengurangi data yang berlebih hingga setiap kategori memiliki jumlah yang sama atau yang *under sampling*. *Under sampling* melibatkan penghapusan beberapa kelas mayoritas untuk menghasilkan distribusi yang seimbang dari semua kelas [13]. Dalam hal ini kategori daun gandum sehat dan daun gandum yang terinfeksi penyakit *Stripe Rust* dikurangi hingga memiliki jumlah yang sama pada masing – masing kategori seperti ditunjukkan pada Tabel 1.

TABEL I
PROSES UNDER SAMPLING

Kategori	Jumlah Data Sebelum Proses Under Sampling	Jumlah Data Sesudah Proses Under Sampling
Sehat	102	97
Septoria	97	97
Stripe Rust	208	97

C. Pemisahan Data

Dalam membuat model *deep learning* diperlukan data untuk melatih model tersebut. Pertimbangan pertama dalam pembangunan *dataset* adalah untuk menentukan ukuran untuk setiap set [15]. Data akan dibagi menjadi data latih untuk dilakukan pelatihan oleh model dan data uji untuk menguji model yang telah dibuat sebelumnya. Dalam menemukan model *deep learning* yang baik perlu dilakukan berbagai pengujian, salah satunya adalah melakukan pengujian dengan perbandingan data latih dan data uji yang berbeda seperti yang ditunjukkan pada Tabel 2.

TABEL II
DISTRIBUSI DATA

Skenario	Perbandingan Data Latih dan Data Uji	Jumlah Data Latih	Jumlah Data Uji
1	90:10	261	30
2	80:20	233	59
3	70:30	203	88
4	60:40	174	117
5	50:50	145	146

D. Augmentasi Citra

Pelatihan jaringan saraf dengan data terbatas mungkin dapat dikurangi dengan pengambilan sampel kebisingan yang ada dalam data pelatihan tetapi tidak dalam data uji yang diambil dari distribusi yang sama. Namun ada solusi lain untuk permasalahan tersebut yaitu augmentasi citra yang merupakan penerapan satu atau lebih deformasi pada kumpulan sampel pelatihan beranotasi yang menghasilkan data pelatihan baru, tambahan, dan berpotensi non-redundan [11]. Sehingga dapat disimpulkan bahwa augmentasi citra merupakan sebuah teknik yang digunakan untuk memperbanyak jumlah citra melalui proses modifikasi pada citra dan dapat meningkatkan kualitas model yang dihasilkan.

E. Perancangan Model

Penelitian ini menggunakan *deep learning* dengan model ResNet152V2 yang diharapkan dapat menghasilkan akurasi dan evaluasi model yang baik. ResNet152V2 merupakan *pre trained model* atau model yang telah dilatih sebelumnya sehingga tidak memerlukan konfigurasi khusus untuk mengatur *layer* di dalamnya. ResNet merupakan kepanjangan dari *Residual Network* yang merupakan jenis jaringan saraf tertentu yang diperkenalkan pada tahun 2015 oleh Kaiming He, Xiangyu Zhang, Shaoqing Ren dan Jian Sun. Selain ResNet152V2, ada beberapa tipe arsitektur ResNet lainnya yaitu ResNet50, ResNet101, ResNet152, ResNet50V2, dan ResNet101V2. Perbedaannya hanya terletak pada banyaknya *layer* yang digunakan dan pada ResNetV2 dibandingkan dengan ResNet yaitu terdapat lapisan *batch normalization* sebelum lapisan bobot di setiap lapisannya. Dasar dari arsitektur ResNet adalah CNN terdiri dari *convolutional layer*, *pooling layer*, dan *fully connected layer* serta penambahan *skip connection* pada setiap beberapa *convolution layer*.

F. Pelatihan Model

Penelitian ini menggunakan arsitektur ResNet152V2 yang memiliki 152 lapisan konvolusi. Arsitektur ResNet152V2 lebih dalam 8x dibanding arsitektur VGG19 tetapi masih memiliki kompleksitas yang lebih rendah [12]. Selanjutnya model dilatih dengan 10 *epochs* atau iterasi dan dengan masukan lapisan sebesar 150x150 supaya tidak membutuhkan waktu yang terlalu lama dalam melakukan pelatihan. Model Resnet152V2 yang digunakan pada penelitian ini ditunjukkan pada Tabel 3.

TABEL III
 RINCIAN MODEL RESNET152V2

Layer (type)	Output Shape	Parameter
Resnet152V2	(None, 5, 5, 2048)	58331648
flatten	(None, 51200)	0
dense	(None, 512)	26214912
dense1	(None, 256)	131328
dense2	(None, 3)	771

G. Evaluasi Metrik

Evaluasi metrik perlu dilakukan untuk menemukan kombinasi model yang terbaik. Evaluasi metrik dapat dilakukan dengan mempertimbangkan beberapa hal yaitu hasil akurasi dan *confusion matrix*. *Confusion matrix* adalah alat evaluasi visual yang digunakan dalam *machine learning*. Kolom *confusion matrix* mewakili hasil kelas prediksi dan baris mewakili hasil kelas sebenarnya sehingga dapat menghitung semua kemungkinan kasus masalah klasifikasi [14]. Dalam *confusion matrix* terdapat beberapa jenis yaitu presisi, *recall*, dan *f1 score*. Akurasi adalah rasio prediksi benar terhadap keseluruhan data. Presisi adalah perbandingan nilai prediksi benar positif dibandingkan dengan total hasil dengan prediksi positif. *Recall* adalah perbandingan nilai prediksi benar positif dengan seluruh data yang benar positif. *F1 score* merupakan perbandingan rata-rata nilai presisi dan *recall* yang dibebankan. Akurasi dan *confusion matrix* dapat dibentuk seperti pada Persamaan (1), (2), (3), dan (4).

$$\text{Akurasi} = \frac{\text{True Positive} + \text{True Negative}}{\text{True Positive} + \text{True Negative} + \text{True Positive} + \text{True Negative}} \tag{1}$$

$$\text{Presisi} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \tag{2}$$

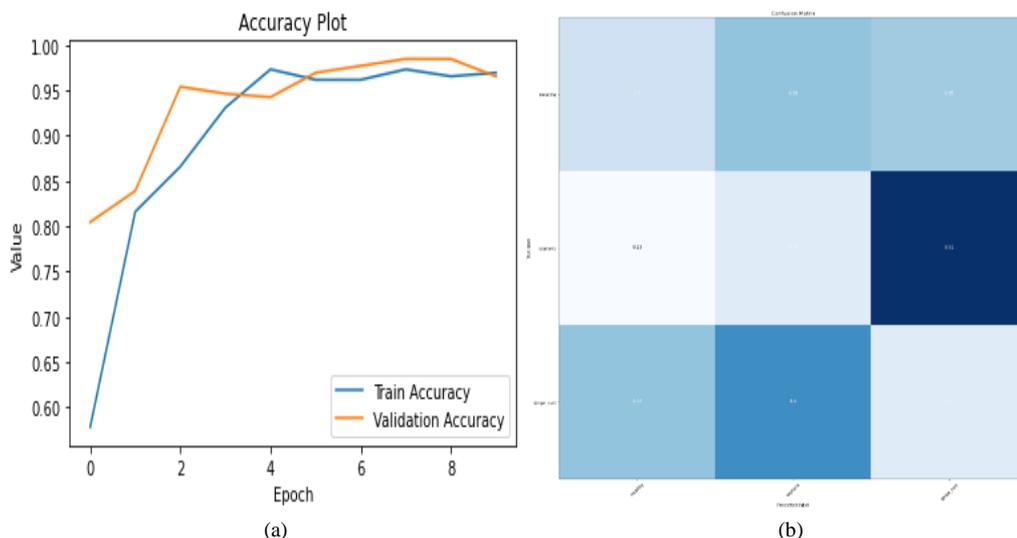
$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \tag{3}$$

$$\text{F1 score} = \frac{2 \times \text{Recall} \times \text{Presisi}}{\text{Recall} + \text{Presisi}} \tag{4}$$

III. HASIL DAN PEMBAHASAN

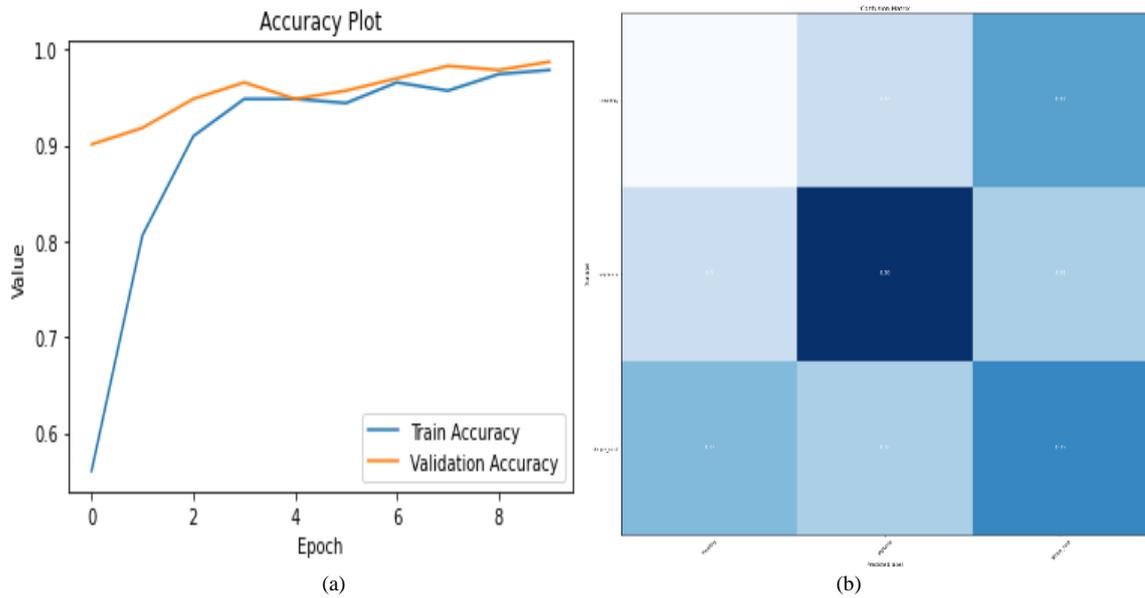
A. Hasil Pengujian Skenario

Skenario 1 menggunakan perbandingan data latih dan data uji sebesar 90:10 dengan jumlah 261 data latih dan 30 data uji. Pelatihan model membutuhkan waktu 30 menit. Setelah melakukan pelatihan model didapatkan hasil akurasi uji terbaik sebesar 96%. Selanjutnya pada tahap evaluasi model menggunakan *confusion matrix* didapatkan presisi sebesar 0,28, *recall* sebesar 0.27, dan *f1 score* sebesar 0.27. Visualisasi akurasi dan *confusion matrix* ditunjukkan pada Gambar 3.



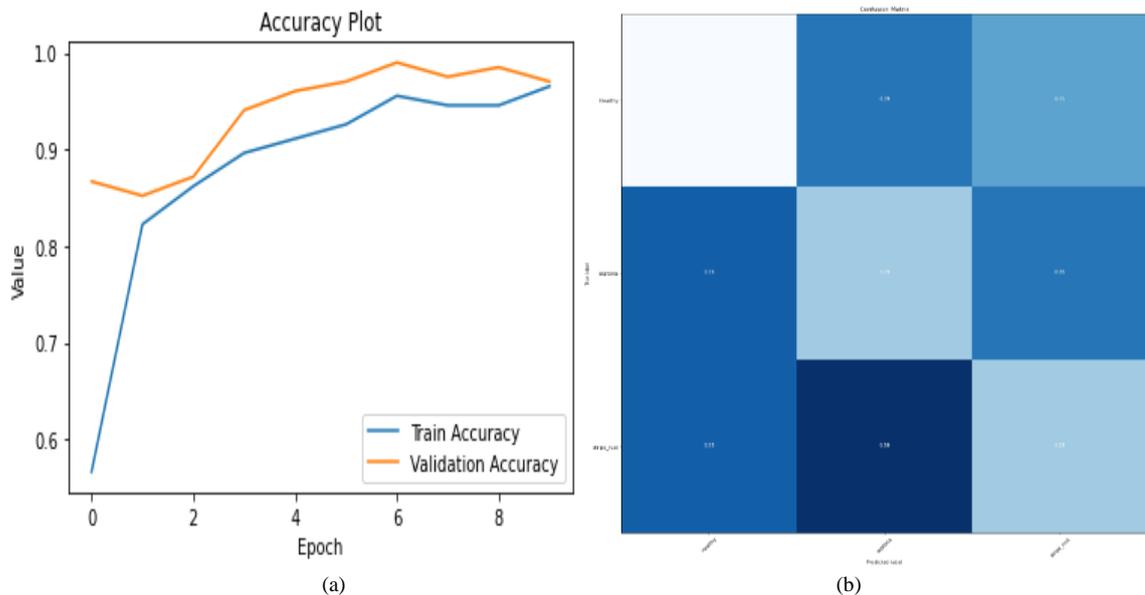
Gambar 3. Visualisasi a) Akurasi dan b) *Confusion matrix*

Pada skenario 2 dengan perbandingan data latih dan data uji sebesar 80:20 dengan jumlah 232 data latih dan 59 data uji. Pelatihan model membutuhkan waktu selama 28 menit dan menghasilkan akurasi uji terbaik sebesar 98%. Selanjutnya pada tahap evaluasi model menggunakan *confusion matrix* menghasilkan presisi, *recall*, dan *f1 score* sebesar 0,35. Visualisasi akurasi dan *confusion matrix* ditunjukkan pada Gambar 4.



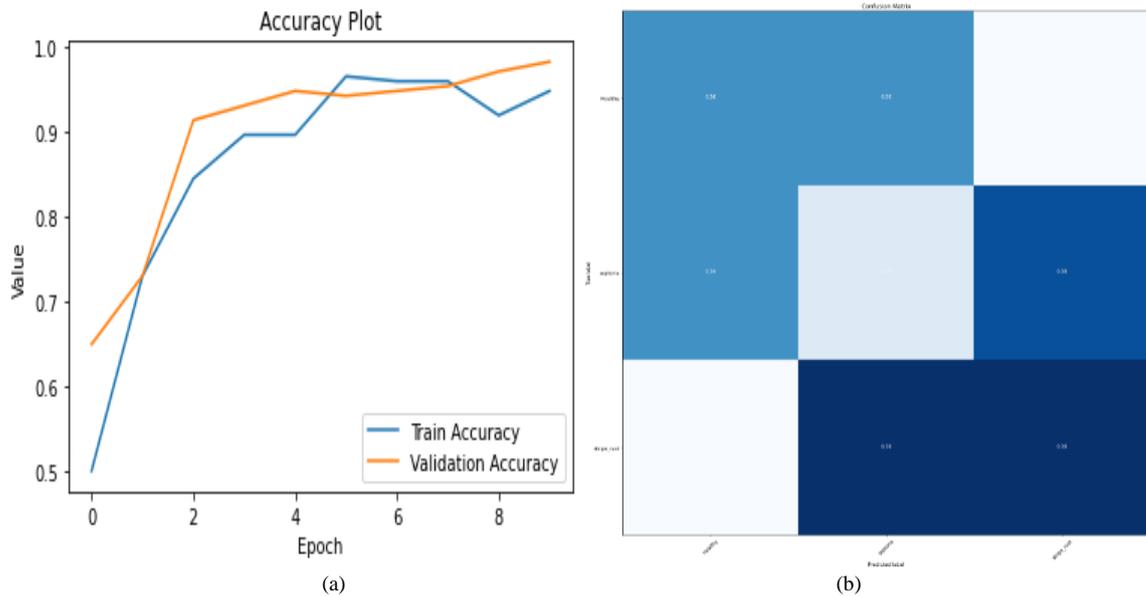
Gambar 4. Visualisasi a) Akurasi dan b) *Confusion matrix*

Skenario 3 menggunakan perbandingan data latih dan data uji sebesar 70:30 dengan jumlah 203 data latih dan 88 data uji. Pelatihan model membutuhkan waktu 30 menit dan menghasilkan akurasi uji terbaik sebesar 97%. Selanjutnya untuk mengevaluasi model maka digunakan *confusion matrix* dan dihasilkan presisi, *recall*, dan *f1 score* sebesar 0,35. Visualisasi akurasi dan *confusion matrix* ditunjukkan pada Gambar 5.



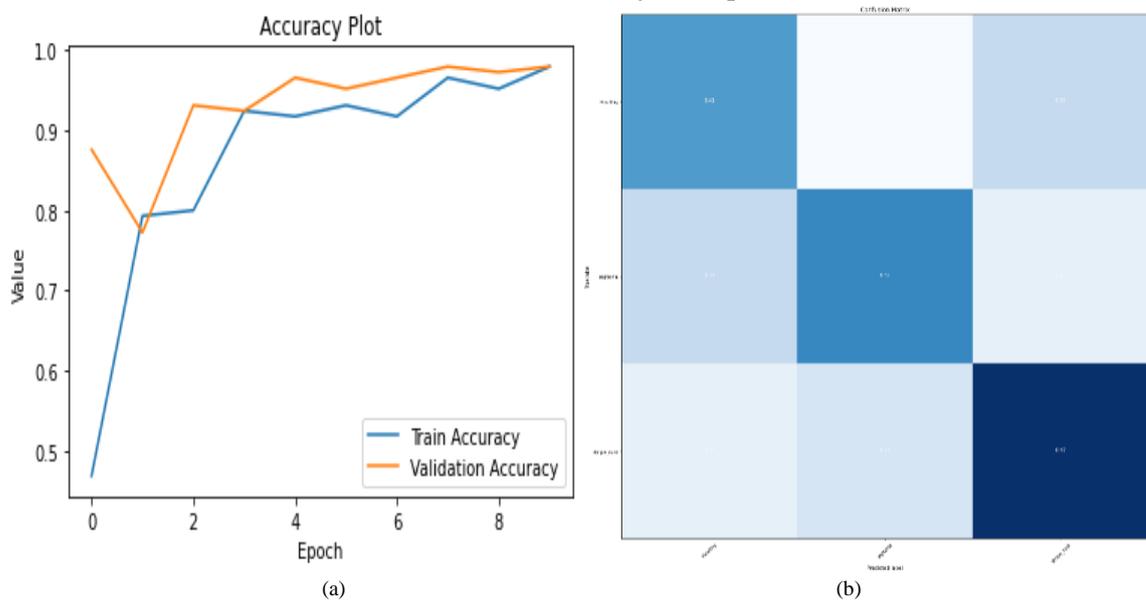
Gambar 5. Visualisasi a) Akurasi dan b) *Confusion matrix*

Pada skenario 4 menggunakan perbandingan data latih dan data uji sebesar 60:40 dengan 174 data latih dan 117 data uji. Pelatihan model membutuhkan waktu 25 menit dan menghasilkan akurasi uji terbaik sebesar 98%. Selanjutnya pada tahap evaluasi model menggunakan *confusion matrix* didapatkan presisi, *recall*, dan *f1 score* sebesar 0,34. Visualisasi akurasi dan *confusion matrix* ditunjukkan pada Gambar 6.



Gambar 6. Visualisasi a) Akurasi dan b) *Confusion matrix*

Pada skenario 5 menggunakan perbandingan data latih dan data uji sebesar 50:50 dengan 145 data latih dan 146 data uji. Pelatihan model membutuhkan waktu selama 27 menit dan menghasilkan akurasi terbaik sebesar 97%. Selanjutnya pada tahap evaluasi model menggunakan *confusion matrix* didapatkan presisi, *recall*, dan *f1 score* sebesar 0,32. Visualisasi akurasi dan *confusion matrix* ditunjukkan pada Gambar 7.

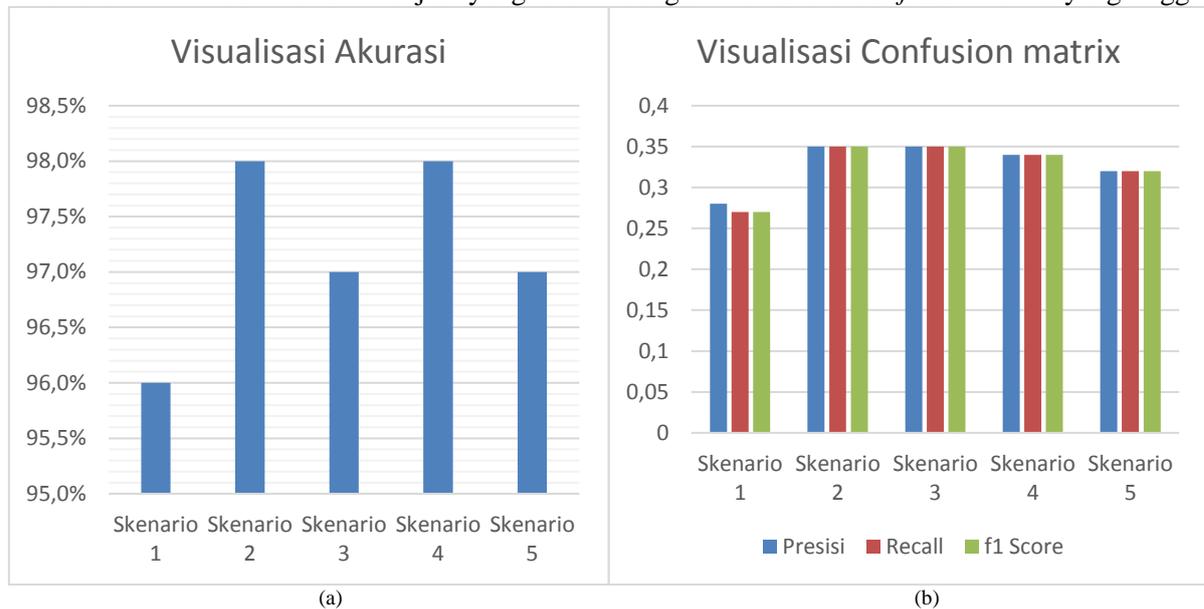


Gambar 7. Visualisasi a) Akurasi dan b) *Confusion matrix*

B. Hasil Keseluruhan Skenario

Setelah melakukan seluruh skenario pengujian, selanjutnya hasil dari setiap skenario dibentuk visualisasi untuk menentukan skenario dengan model yang terbaik. Akurasi dan Model yang terbaik memiliki akurasi dan nilai *confusion matrix* yang tinggi dibanding dengan lainnya sehingga dapat mendeteksi penyakit lebih akurat. Skenario 2 dan skenario 4 memiliki akurasi tertinggi dibandingkan dengan yang lain. Sedangkan pada nilai *confusion matrix*, skenario 2 dan 3 memiliki nilai yang tertinggi dibandingkan dengan yang lain. Sehingga dapat disimpulkan bahwa skenario 2 menjadi model yang terbaik karena memiliki nilai akurasi dan *confusion matrix* yang tertinggi

dibandingkan dengan lainnya. Visualisasi akurasi dan *confusion matrix* ditunjukkan pada Gambar 8. Model yang terbaik adalah model yang memiliki akurasi tinggi dan *confusion matrix* yang memiliki nilai tinggi. Pada skenario yang telah dilakukan maka skenario 2 menjadi yang terbaik dengan akurasi dan *confusion matrix* yang tinggi.



Gambar 7. Visualisasi Seluruh Skenario a) Akurasi dan b) *Confusion matrix*

IV. KESIMPULAN

Berdasarkan hasil penelitian dapat diambil kesimpulan yaitu metode *Residual Network* (ResNet) dapat melakukan klasifikasi penyakit dengan nilai akurasi lebih dari 95% dengan pemisahan data yang berbeda. Hasil akurasi terbaik terdapat pada skenario 2 karena memiliki nilai akurasi dan *confusion matrix* yang lebih tinggi dibandingkan skenario lainnya. Skenario 2 menghasilkan akurasi sebesar 98% dan *confusion matrix* sebesar 0,35.

Untuk penelitian lebih lanjut disarankan menggunakan data yang lebih banyak supaya hasil akurasi dan *confusion matrix* dapat meningkat. Selain itu dapat melakukan percobaan dengan parameter masukan lapisan yang berbeda supaya mengetahui tingkat akurasinya.

DAFTAR PUSTAKA

- [1] M. Figueroa, K. E. Hammond-Kosack, and P. S. Solomon, "A review of wheat diseases—a field perspective," *Mol. Plant Pathol.*, vol. 19, no. 6, pp. 1523–1536, 2018, doi: 10.1111/mpp.12618.
- [2] S. Tira, "Tekan Ketergantungan Impor, Masyarakat Diminta Gunakan Tepung Lokal", *Merdeka*, 19 Maret 2021, [Online]. Tersedia: <https://www.merdeka.com/uang/tekan-ketergantungan-impor-masyarakat-diminta-gunakan-tepung-lokal.html> [Diakses: 6 September 2021].
- [3] R. C. Downie et al., "Septoria Nodorum Blotch of Wheat: Disease Management and Resistance Breeding in the Face of Shifting Disease Dynamics and a Changing Environment," *Phytopathology*, p. PHYTO-07-20-028, 2021, doi: 10.1094/phyto-07-20-0280-rww.
- [4] Z. Mi, X. Zhang, J. Su, D. Han, and B. Su, "Wheat Stripe Rust Grading by Deep Learning With Attention Mechanism and Images From Mobile Devices," *Front. Plant Sci.*, vol. 11, no. September, pp. 1–11, 2020, doi: 10.3389/fpls.2020.558126.
- [5] A. Voulodimos, N. Doulamis, A. Doulamis, and E. Protopapadakis, "Deep Learning for Computer Vision: A Brief Review," *Comput. Intell. Neurosci.*, vol. 2018, 2018, doi: 10.1155/2018/7068349.
- [6] L. Zhou, C. Zhang, F. Liu, Z. Qiu, and Y. He, "Application of Deep Learning in Food: A Review," *Compr. Rev. Food Sci. Food Saf.*, vol. 18, no. 6, pp. 1793–1811, 2019, doi: 10.1111/1541-4337.12492.
- [7] A. Tsany and R. Dzaky, "Deteksi Penyakit Tanaman Cabai Menggunakan Metode Convolutional Neural Network," vol. 8, no. 2, pp. 3039–3055, 2021.
- [8] M. Metode, F. Multiple, C. Decision, M. Fmcdm, and D. Yogyakarta, "Indonesian Journal of Business Intelligence," vol. 3, no. 2, pp. 54–60, 2020.
- [9] Y. S. HARIYANI, S. HADIYOSO, and T. S. SIADARI, "Deteksi Penyakit Covid-19 Berdasarkan Citra X-Ray Menggunakan Deep Residual Network," *ELKOMIKA J. Tek. Energi Elektr. Telekomun. Tek. Elektron.*, vol. 8, no. 2, p. 443, 2020, doi: 10.26760/elkomika.v8i2.443.
- [10] O. Getch, "Wheat Leaf dataset", Kaggle, 2021, [online]. Tersedia: <https://www.kaggle.com/olyadgetch/wheat-leaf-dataset> [Diakses: 25 Agustus 2021].
- [11] H. Salehinejad, S. Valaee, T. Dowdell, and J. Barfett, "IMAGE AUGMENTATION USING RADIAL TRANSFORM FOR TRAINING DEEP NEURAL NETWORKS Department of Electrical & Computer Engineering, University of Toronto, Toronto, Canada Department of Medical Imaging, St. Michael's Hospital, University of Toronto, Toronto," 2018 IEEE Int. Conf. Acoust. Speech Signal Process., pp. 3016–3020, 2018.
- [12] S. S. Han et al., "Deep neural networks show an equivalent and often superior performance to dermatologists in onychomycosis diagnosis: Automatic construction of onychomycosis datasets by region-based convolutional deep neural network," *PLoS One*, vol. 13, no. 1, pp. 1–14, 2018, doi: 10.1371/journal.pone.0191493.
- [13] F. Rayhan, S. Ahmed, A. Mahbub, R. Jani, S. Shatabda, and D. M. Farid, "CUSBoost: Cluster-Based Under-Sampling with Boosting for Imbalanced Classification," 2nd Int. Conf. Comput. Syst. Inf. Technol. Sustain. Solut. CSITSS 2017, pp. 1–5, 2018, doi: 10.1109/CSITSS.2017.8447534.
- [14] J. Xu, Y. Zhang, and D. Miao, "Three-way confusion matrix for classification: A measure driven view," *Inf. Sci. (Ny.)*, vol. 507, pp. 772–794, 2020, doi: 10.1016/j.ins.2019.06.064.
- [15] B. Eagan, M. Misfeldt, and A. Siebert-Evenstone, *Advances in Quantitative Ethnography*, vol. 1, 2019.