



Evaluasi Kinerja CNN dengan Optimizer RMSprop, Adam dan SGD dalam Klasifikasi Penyakit Daun Anggur

Wahib Rohman Nur Rifa'i^{a,1,*}, Danang Erwanto^{a,2}, Iska Yanuartanti^{a,3}

^a Program Studi Teknik Elektro, Universitas Islam Kediri, Jl. Sersan Suharmadji No. 38 Kota Kediri, Jawa Timur, Indonesia

¹ wahib.chelsea@gmail.com *, ² danangerwanto@uniska-kediri.ac.id, ³ iskayauartanti@uniska-kediri.ac.id

* Corresponding Author

ARTICLE INFO

Article History

Submission : 25-03-2025

Revision : 26-03-2025

Accepted : 27-03-2025

Kata Kunci:

Convolutional Neural Network (CNN), Klasifikasi Penyakit Tanaman, Deteksi Penyakit Daun Anggur,, Akurasi Model CNN, Machine Learning dalam Pertanian, Pengenalan Citra Tanaman Daun Anggur.

ABSTRAK

Penelitian ini bertujuan untuk membandingkan kinerja metode *Convolutional Neural Network* (CNN) dalam mendeteksi dan mengklasifikasikan penyakit pada daun tanaman anggur, serta mengukur tingkat akurasi dari masing-masing model CNN dengan cara membandingkan tiga *optimizer*. *Dataset* daun tanaman anggur yang terinfeksi penyakit digunakan dan diproses dengan teknik augmentasi data. Model CNN yang diterapkan menggunakan arsitektur *DenseNet-121* dengan *transfer learning* dan diuji dengan berbagai *optimizer*: RMSprop (*Root Mean Square Propagation*), Adam, dan SGD (*Stochastic Gradient Descent*) pada 3 nilai *learning rate* yang berbeda. Hasil evaluasi menggunakan *confusion matrix* menunjukkan bahwa akurasi tertinggi diperoleh pada *learning rate* 0.001, dengan Adam sebagai *optimizer* terbaik yang mencapai akurasi 99.45%. Secara umum, semua *optimizer* menunjukkan performa optimal pada *learning rate* 0.1 dan 0.001 dengan akurasi di atas 99%, sementara penurunan akurasi terjadi pada *learning rate* 0.00001, yang mencapai sekitar 97.73% untuk semua *optimizer*. Temuan ini menegaskan bahwa pemilihan *learning rate* yang tepat berperan penting dalam meningkatkan akurasi CNN dalam tugas klasifikasi.

This is an open access article under license [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/).



1. Pendahuluan

Tanaman anggur (*Vitis vinifera*) memiliki nilai ekonomi tinggi di Indonesia karena meningkatnya permintaan pasar baik untuk dikonsumsi secara langsung atau sebagai bahan baku industri minuman dan produk olahan lainnya. Namun pertumbuhan tanaman ini seringkali terhambat oleh serangan hama dan penyakit yang dapat menyebabkan kerugian signifikan. Penyakit tersebut dapat mengganggu pertumbuhan tanaman anggur hingga 40-70% [1], sehingga menjadi tantangan serius bagi petani dan industri pengolahan anggur di Indonesia.

Penyakit-penyakit umum pada daun anggur seperti *Black Rot*, *Black Measles*, dan *Leaf Blight*, umumnya dapat dideteksi melalui pengamatan visual. Sayangnya pendekatan tersebut


mempunyai keterbatasan dalam hal akurasi, terutama bagi petani yang belum memiliki pengalaman dalam identifikasi gejala penyakit pada tanaman anggur secara spesifik [2]. Sehingga diperlukan metode pendeteksi yang lebih akurat dan efisien untuk membantu petani dalam meningkatkan produktifitas dan kualitas tanaman anggur di Indonesia.

Seiring perkembangan teknologi, metode pembelajaran mesin, khususnya *Convolutional Neural Network* (CNN), menunjukkan potensi besar dalam klasifikasi penyakit tanaman dengan tingkat akurasi yang tinggi. CNN, dengan kemampuannya mengekstraksi fitur otomatis melalui lapisan konvolusi, telah terbukti efektif dalam mendeteksi penyakit pada tanaman, termasuk tanaman anggur [3]. Beberapa penelitian telah menerapkan CNN untuk klasifikasi penyakit pada daun. Penelitian yang dilakukan Jihan Rihadatul Aisyah dan Agi Prasetyadi (2023) membandingkan metode CNN dan RNN (*Recurrent Neural Network*) untuk klasifikasi penyakit daun kentang menggunakan teknik *transfer learning* dan augmentasi data. Hasilnya, arsitektur VGG16 dengan *dense layer* 75 mencapai akurasi tertinggi sebesar 86%, sementara kombinasi VGG16 dan LSTM dengan *dense layer* 100 menunjukkan performa terendah dengan akurasi 24% [4]. Penelitian oleh Jafivah Dwi Nurcahyati dkk. (2022) menggunakan CNN untuk mengklasifikasikan penyakit pada daun jagung, dengan hasil terbaik diperoleh menggunakan kernel 3×3 dan optimizer Adam, mencapai akurasi 84% pada data uji. Studi ini menunjukkan bahwa metode CNN efektif dalam deteksi penyakit tanaman, sehingga dapat menjadi referensi untuk klasifikasi penyakit pada daun anggur [5]. Penelitian oleh Sholikhin dan Alexandro (2022) menggunakan CNN untuk mengklasifikasikan penyakit daun melon dengan akurasi 90% pada aplikasi smartphone dan 89% pada komputer. Studi ini menunjukkan bahwa Computer Vision dapat mendeteksi penyakit tanaman secara otomatis, sehingga membantu petani dalam identifikasi yang lebih cepat dan akurat [6].

Penelitian ini bertujuan untuk membandingkan kinerja model CNN dengan arsitektur DenseNet-121 dalam mendeteksi penyakit pada daun anggur dan mengukur performanya menggunakan berbagai optimizer seperti RMSprop (*Root Mean Square Propagation*), Adam dan SGD (*Stochastic Gradient Descent*). CNN dipilih karena kemampuannya dalam mengekstraksi fitur visual yang kompleks dari citra daun secara otomatis [7], [8], sehingga lebih unggul dibandingkan metode konvensional dalam mendeteksi pola dan karakteristik penyakit. Tiga optimizer RMSprop, Adam dan SGD dipilih untuk dibandingkan karena memiliki karakteristik yang berbeda dalam proses pembaruan bobot model. RMSprop dikenal mampu menangani perubahan gradien yang fluktuatif dengan membagi learning rate berdasarkan rata-rata pergerakan eksponensial dari gradien sebelumnya, sehingga cocok untuk data dengan tingkat perubahan tinggi [9]. Adam menggabungkan keunggulan RMSprop dan momentum, menjadikannya lebih adaptif terhadap perubahan gradien serta sering kali menghasilkan konvergensi yang lebih cepat [10]. Sementara itu, SGD adalah metode dasar yang bekerja dengan pembaruan bobot secara langsung berdasarkan gradien tanpa mempertimbangkan sejarah pergerakan sebelumnya, sehingga sering digunakan sebagai tolok ukur dalam mengukur efektivitas *optimizer* yang lebih kompleks [11]. Diharapkan, penelitian ini dapat menyediakan solusi deteksi penyakit yang lebih cepat, akurat, dan efisien, serta membantu petani dalam pengelolaan tanaman yang lebih baik dan ramah lingkungan.

2. Metode Penelitian

Dalam penelitian ini, metode yang digunakan dirancang untuk mengevaluasi kinerja CNN dalam klasifikasi penyakit daun anggur dengan membandingkan tiga jenis *optimizer*, yaitu RMSprop, Adam, dan SGD. Proses penelitian mencakup tahap pengumpulan dan pemrosesan data, pembangunan arsitektur CNN berbasis DenseNet-121, serta pelatihan dan pengujian model menggunakan parameter yang telah ditetapkan. Evaluasi dilakukan dengan mengukur tingkat akurasi dan performa masing-masing optimizer untuk menentukan pendekatan yang paling optimal dalam mendeteksi penyakit pada daun anggur. Tahapan penelitian yang dilakukan ditampilkan pada Gambar 1 berikut.



Gambar 1. Tahapan Penelitian

Gambar 1. menggambarkan tahapan-tahapan atau rancangan penelitian yang akan dilakukan pada penelitian ini antara lain pengambilan *dataset*, *split data test*, *pre-processing* dan augmentasi data, train model dengan CNN, evaluasi kinerja, analisis hasil kinerja dan kesimpulan.

Penelitian ini menggunakan *dataset* yang didapatkan dari situs *repository Kaggle*. Dengan jumlah citra yang digunakan sebanyak 9.027 citra daun anggur yang terdiri dari 4 jenis kelas yaitu *healthy*, *black rot*, *ESCA*, *leaf blight* dan sehat. Rincian *dataset* yang digunakan dapat dilihat pada Tabel 1.

Tabel 1: Citra daun anggur [12]

Citra				
Penyakit	Black rot	ESCA	<i>leaf blight</i>	Sehat
Jumlah <i>Dataset</i>	2360	2400	2152	2115

Dari *dataset* penyakit tanaman anggur, sebanyak 9027 citra dibagi menjadi dua *subset* yaitu *data training* dan *data testing* dengan pembagian data menjadi 80% untuk *data training* sebanyak 7222 citra daun anggur dan 20% untuk data testing sebanyak 1805 citra daun anggur.

Data citra daun anggur yang sudah dikumpulkan kemudian di-*pre-processing* dengan cara mengubah ukuran (*resize*) citra untuk menyeragamkan ukuran pikselnya menjadi 224 x 224 piksel agar ukuran *file* citra lebih kecil sehingga mempercepat proses komputasi.

Untuk mendapatkan performa yang optimal maka membutuhkan data dengan jumlah yang banyak. Karena membutuhkan data yang banyak, maka dilakukan data augmentasi untuk memperbanyak variasi data citra. Augmentasi yang akan dilakukan yaitu *rescale*, *rotate*, *zoom* dan *flip*. *Rescale* dilakukan untuk menormalisasi nilai piksel citra dengan membagi setiap piksel dengan nilai maksimum, sehingga skala warna citra menjadi lebih seragam. Teknik *zoom* digunakan untuk memperbesar citra sesuai dengan faktor perbesaran yang telah ditentukan, memungkinkan model mengenali fitur penyakit pada berbagai skala. *Rotation* diterapkan dengan memutar citra pada sudut tertentu untuk meningkatkan ketahanan model terhadap variasi orientasi daun. Sementara itu, *flip* digunakan untuk membalik citra baik secara vertikal maupun horizontal, sehingga model dapat belajar dari tampilan daun dalam berbagai posisi.


Penerapan teknik augmentasi data yang akan dilakukan pada penelitian ini dapat dilihat pada Tabel 2. Berikut.

Tabel 2: Penerapan augmentasi data

No	Metode Augmentasi	<i>Range</i>
1	<i>Scale</i>	1/255,0
2	<i>Rotation</i>	20
3	<i>Width shift</i>	0,2
4	<i>Height shift</i>	0,2
5	<i>Horizontal Flip</i>	<i>True</i>


Seperti yang ditunjukkan pada Tabel 2, proses augmentasi melibatkan *rescale* dengan nilai 1/255,0 untuk normalisasi piksel, *rotation* hingga 20 derajat untuk mengubah orientasi citra, serta *width shift* dan *height shift* masing-masing sebesar 0,2 untuk memberikan pergeseran horizontal dan vertikal. Selain itu, diterapkan juga horizontal *flip* untuk membalik citra guna meningkatkan ketahanan model terhadap variasi posisi daun. Dengan kombinasi teknik augmentasi ini, diharapkan model dapat lebih *robust* dalam mengenali pola penyakit pada daun

anggur, meskipun terdapat perbedaan pencahayaan, orientasi, atau skala dalam citra masukan. Hasil augmentasi data ditampilkan pada Gambar 2.



Gambar 2. Hasil augmentasi data

Setelah melakukan *pre-processing* data dan augmentasi data maka selanjutnya melakukan *train* data dengan model CNN. Arsitektur CNN yang digunakan pada penelitian ini yaitu DenseNet-121 (*Densely Connected Convolutional Network* dengan 121 lapisan). DenseNet-121 menerapkan pola koneksi padat dimana setiap *layer* terhubung dengan semua *layer* berikutnya secara *feed-forward*. Pendekatan ini memungkinkan fitur-fitur dari *layer* sebelumnya dapat digunakan kembali oleh *layer-layer* selanjutnya, menghasilkan pembelajaran yang lebih efisien [13]. Arsitektur DenseNet digambarkan oleh Gambar 3.



Gambar 3. Arsitektur DenseNet-121 terdiri dari empat lapisan *Dense Block* dan tiga lapisan *Transition Layer* [14]

Pada proses *training*, data dengan CNN diuji dengan parameter yang bervariasi seperti yang disajikan Tabel 3 berikut :

Tabel 3: Penerapan augmentasi data

No	Parameter	Nilai
1	Arsitektur	DenseNet121 Transfer Learning
2	Fungsi Aktivasi	ReLU
3	<i>Optimizer</i>	RMSprop, Adam, dan SGD
4	<i>Batch size</i>	64
5	<i>Epoch</i>	20
6	<i>Learning rate</i>	10^{-1} , 10^{-3} , dan 10^{-5}

Tabel 3 di atas merangkum parameter yang digunakan dalam penelitian ini untuk mengevaluasi performa model CNN dalam klasifikasi penyakit daun anggur. Arsitektur DenseNet121 dengan pendekatan *transfer learning* dipilih karena kemampuannya dalam mengekstraksi fitur secara efisien [15], [16]. Fungsi aktivasi ReLU digunakan untuk mempercepat proses konvergensi [17], sementara tiga jenis *optimizer*—RMSprop, Adam, dan SGD—diimplementasikan untuk membandingkan performa pembelajaran model. Dengan *batch size* sebesar 64 dan *epoch* sebanyak 20, model diuji dengan tiga variasi *learning rate* (10^{-1} , 10^{-3} , dan 10^{-5}) guna memahami pengaruhnya terhadap akurasi klasifikasi. Kombinasi parameter ini diharapkan dapat menghasilkan model yang optimal dalam mendeteksi penyakit pada daun anggur secara akurat dan efisien.

Setelah model dilatih, selanjutnya model dianalisis dan dievaluasi dengan *Confusion Matrix* seperti akurasi, presisi, *recall*, dan *F1 score* [18] pada masing-masing *optimizer* dengan *learning rate* 10^{-1} , 10^{-3} , dan 10^{-5} . *Confusion Matrix* memiliki keunggulan dalam memberikan gambaran yang lebih rinci mengenai performa klasifikasi model dengan menunjukkan jumlah prediksi yang benar dan salah untuk setiap kelas. Selain itu, metrik ini memungkinkan analisis mendalam terkait keseimbangan antara presisi dan *recall*, yang sangat penting dalam klasifikasi penyakit, terutama untuk menghindari kesalahan deteksi yang dapat berdampak pada pengambilan keputusan petani.

3. Hasil dan Pembahasan

Pengujian dalam penelitian ini dilakukan untuk mengevaluasi kinerja masing-masing *optimizer*, yaitu RMSprop, Adam, dan SGD, dalam mengoptimalkan model DenseNet-121 menggunakan teknik *Transfer Learning*. Evaluasi ini bertujuan untuk menganalisis sejauh mana setiap *optimizer* mampu meningkatkan akurasi klasifikasi penyakit pada daun anggur, serta bagaimana pengaruh *learning rate* terhadap performa model.


3.1. Uji Coba *Optimizer* RMSprop dengan DenseNet-121 *Transfer Learning*

Hasil pengujian *optimizer* pertama model CNN dilakukan dengan membandingkan nilai akurasi menggunakan *optimizer* RMSprop pada model DenseNet-121 dengan *transfer learning*. Pengujian dilakukan dengan tiga nilai *learning rate*, yaitu 0.1, 0.001, dan 0.00001, selama 20 *epoch*. Tabel 3 menyajikan hasil uji coba *optimizer* RMSprop dengan DenseNet-121 *Transfer Learning*.

Tabel 4: Hasil uji coba *optimizer* RMSprop dengan DenseNet-121 *Transfer Learning*

Learning Rate	0.1	0.001	0.00001
Akurasi %	99.17	99.39	98.73

Hasil uji coba dengan *optimizer* RMSprop akurasi terbesar dicapai pada *learning rate* 0.00001 dengan nilai akurasi yang diperoleh sebesar 98.73%. Detail hasil pengujian disajikan pada gambar 4 berikut.



Gambar 4. Grafik hasil uji coba pada *optimizer* RMSprop model CNN dengan DenseNet-121 *Transfer Learning* (a) grafik akurasi (b) grafik loss


Pada gambar 5 berikut adalah hasil klasifikasi yang menunjukkan evaluasi performa model CNN *optimizer* RMSprop dengan Dense-Net121. Matrik yang digunakan meliputi *Precision*, *Recall*, dan *F1-score*, serta *support* untuk setiap kelas.

Classification Report:

	precision	recall	f1-score	support
Grape__Black_rot	0.99	0.99	0.99	472
Grape__Esca_(Black_Measles)	0.99	0.99	0.99	480
Grape__Leaf_blight_(Isariopsis_Leaf_Spot)	1.00	1.00	1.00	430
Grape__healthy	1.00	1.00	1.00	423
accuracy			0.99	1805
macro avg	0.99	0.99	0.99	1805
weighted avg	0.99	0.99	0.99	1805

Gambar 5. Hasil klasifikasi *dataset* penyakit tanaman anggur dengan arsitektur DenseNet-121 dengan RMSprop model CNN

Hasil klasifikasi pada gambar 5, menunjukkan performa yang sangat baik dengan nilai *Precision*, *Recall*, dan *F1-score* hampir sempurna untuk semua kelas. Dari keseluruhan hasil tersebut menunjukkan bahwa model dapat mengenali penyakit tanaman anggur dengan tingkat kesalahan yang sangat rendah. Dari hasil klasifikasi tersebut diperoleh matrik evaluasinya seperti yang disajikan oleh Gambar 6.



Gambar 6. Hasil *Confusion Matrix* klasifikasi *dataset* penyakit tanaman anggur dengan arsitektur DenseNet-121 dengan RMSprop

Pada data *confusion matrix* gambar 6 menunjukkan bahwa akurasi tinggi dan mayoritas prediksi model benar, dengan hanya beberapa kesalahan kecil. Kelas yang sedikit sulit dibedakan adalah "Grape_Black_rot" dan "Grape_Esca(Black_Measles)" dengan 4 sampai dengan 7 gambar yang memiliki kesamaan. Kelas "Grape_Leaf_blight(Isariopsis_Leaf_Spot)" dan "Grape_healthy" memiliki performa sempurna (tanpa kesalahan prediksi).


3.2. Hasil Uji Coba *Optimizer Adam* dengan DenseNet-121 *Transfer Learning*

Hasil pengujian *optimizer* kedua model CNN dilakukan dengan membandingkan nilai akurasi menggunakan *optimizer Adam* pada model DenseNet-121 dengan *transfer learning*. Pengujian dilakukan dengan tiga nilai *learning rate*, yaitu 0.1, 0.001, dan 0.00001, selama 20 *epoch*. Tabel 5 menyajikan hasil uji coba *optimizer Adam* dengan DenseNet-121 *transfer learning*.

Tabel 5: Hasil uji coba *optimizer Adam* dengan DenseNet-121 *Transfer Learning*

Learning Rate	0.1	0.001	0.00001
Akurasi %	99.28	99.45	97.73

Hasil uji coba dengan *optimizer Adam* akurasi terbesar dicapai pada *learning rate* 0.001 dengan nilai akurasi yang diperoleh sebesar 99.45%. Detail hasil pengujian disajikan pada Gambar 7 berikut.



Gambar 7. Grafik hasil uji coba pada *optimizer* Adam model CNN dengan DenseNet-121 *Transfer Learning* (a) grafik akurasi (b) grafik loss


Pada gambar 8 berikut adalah hasil klasifikasi yang menunjukkan evaluasi performa model CNN *optimizer* Adam dengan DenseNet-121. Matrik yang digunakan meliputi *Precision*, *Recall*, dan *F1-score*, serta *support* untuk setiap kelas.

Classification Report:

	precision	recall	f1-score	support
Grape__Black_rot	1.00	0.97	0.98	472
Grape__Esca_(Black_Measles)	0.97	1.00	0.98	480
Grape__Leaf_blight_(Isariopsis_Leaf_Spot)	1.00	1.00	1.00	430
Grape__healthy	1.00	1.00	1.00	423
accuracy			0.99	1805
macro avg	0.99	0.99	0.99	1805
weighted avg	0.99	0.99	0.99	1805

Gambar 8. Hasil klasifikasi *dataset* penyakit tanaman anggur dengan arsitektur DenseNet-121 dengan Adam model CNN

Hasil klasifikasi gambar 8, menunjukkan performa yang sangat baik dan tinggi dengan nilai *F1-score* mendekati 1.00 untuk semua kelas. Dari keseluruhan hasil tersebut menunjukkan bahwa model dapat mengenali penyakit tanaman anggur dengan tingkat kesalahan yang sangat rendah.



Gambar 9. Hasil Confusion Matrix klasifikasi *dataset* penyakit tanaman anggur dengan arsitektur DenseNet-121 dengan Adam model CNN

Pada data confusion matrix gambar 9 menunjukkan bahwa akurasi model sangat tinggi, karena sebagian besar prediksi benar.

Kelas "Grape_Black_rot" dan "Grape_Esca_(Black_Measles)" mengalami beberapa kesalahan klasifikasi satu sama lain, mungkin karena fitur visualnya serupa. Tidak ada kesalahan klasifikasi untuk kelas "Grape_Leaf_blight_(Isariopsis_Leaf_Spot)" dan "Grape_healthy", menunjukkan model sangat baik dalam mengenali keduanya.


3.3. Hasil Uji Coba *Optimizer* SGD dengan DenseNet-121 *Transfer Learning*

Hasil pengujian *optimizer* ketiga model CNN dilakukan dengan membandingkan nilai akurasi menggunakan *optimizer* SGD pada model DenseNet-121 dengan *transfer learning*. Pengujian dilakukan dengan tiga nilai *learning rate*, yaitu 0.1, 0.001, dan 0.00001, selama 20 *epoch*. Tabel 6 menyajikan hasil uji coba *optimizer* SGD dengan DenseNet-121 *transfer learning*.

Tabel 6: Hasil uji coba *optimizer* SGD dengan DenseNet-121 *Transfer Learning*

Learning Rate	0.1	0.001	0.00001
Akurasi %	99.15	99.37	97.72

Hasil uji coba dengan *optimizer* SGD akurasi terbesar dicapai pada *learning rate* 0.001 dengan nilai akurasi yang diperoleh sebesar 99.37%. Detail hasil pengujian disajikan pada Gambar 10 berikut.



Gambar 10. Grafik hasil uji coba pada *optimizer* SGD model CNN dengan DenseNet-121 *Transfer Learning* (a) grafik akurasi (b) grafik *loss*


Pada Gambar 11 berikut adalah hasil klasifikasi yang menunjukkan evaluasi performa model CNN *optimizer* SGD dengan DenseNet-121. Matrik yang digunakan meliputi *Precision*, *Recall*, dan *F1-score*, serta *support* untuk setiap kelas.

Classification Report:

	precision	recall	f1-score	support
Grape__Black_rot	0.99	0.98	0.98	472
Grape__Esca_(Black_Measles)	0.98	0.99	0.98	480
Grape__Leaf_blight_(Isariopsis_Leaf_Spot)	1.00	1.00	1.00	430
Grape__healthy	1.00	1.00	1.00	423
accuracy			0.99	1805
macro avg	0.99	0.99	0.99	1805
weighted avg	0.99	0.99	0.99	1805

Gambar 11. Hasil klasifikasi *dataset* penyakit tanaman anggur dengan arsitektur DenseNet-121 dengan SGD model CNN

Hasil klasifikasi pada gambar 10, menunjukkan performa yang sangat baik dan akurasi yang tinggi. Kelas "Grape__Black_rot" dan "Grape__Esca_(Black_Measles)" memiliki *Precision* dan *Recall* sedikit lebih rendah dibandingkan kelas lainnya, mengindikasikan adanya kesalahan kecil dalam membedakan kedua kelas ini. Kelas "Grape__Leaf_blight_(Isariopsis_Leaf_Spot)" dan "Grape__healthy" memiliki performa sempurna dengan *Precision* dan *Recall* = 1.00, artinya semua sampel diklasifikasikan dengan benar.



Gambar 12. Hasil *Confusion Matrix* klasifikasi *dataset* penyakit tanaman anggur dengan arsitektur DenseNet-121 dengan SGD model CNN

Pada data *Confusion Matrix* gambar 12 tersebut menunjukkan bahwa akurasi model memiliki performa tinggi. Kelas "Grape__Black_rot" memiliki 9 kesalahan klasifikasi ke "Grape__Esca_(Black_Measles)", Model sedikit kesulitan membedakan antara kedua penyakit ini. Kelas "Grape__Esca_(Black_Measles)" memiliki 7 kesalahan klasifikasi ke "Grape__Black_rot", Mirip dengan pola sebelumnya, menunjukkan adanya kemiripan antara fitur kedua kelas ini. Kelas "Grape__Leaf_blight_(Isariopsis_Leaf_Spot)" dan "Grape__healthy" diklasifikasikan dengan sempurna (tanpa kesalahan) dengan akurasi 100%.

3.4. Perbandingan Akurasi Pada *Optimizer* RMSprop, Adam dan SGD dengan DenseNet-121 *Transfer Learning* Model CNN

Hasil perbandingan dari ketiga uji coba model CNN menggunakan *optimizer* RMSprop, Adam dan SGD dengan DenseNet-121 *transfer learning* dapat dilihat dalam Tabel 6.

Tabel 7: Perbandingan Akurasi Pada *Optimizer* RMSprop, Adam dan SGD dengan DenseNet-121 *Transfer Learning* Model CNN

<i>Learning Rate</i>	Akurasi %		
	RMSprop	Adam	SGD
0.1	99.17	99.28	99.17
0.001	99.39	99.45	99.39
0.00001	97.73	97.73	97.73

Tabel 5 menyajikan hasil perbandingan akurasi dari setiap percobaan yang dilakukan menggunakan tiga *optimizer*, yaitu RMSprop, Adam, dan SGD, dengan variasi *learning rate* sebesar 0.1, 0.001, dan 0.00001 serta jumlah *epoch* 20. Dari hasil pengujian, diperoleh bahwa nilai akurasi tertinggi dalam deteksi penyakit pada daun anggur menggunakan DenseNet-121 dengan *transfer learning* dicapai oleh *optimizer* Adam dengan *learning rate* 0.001, yaitu sebesar 99.45%.

Hasil ini menunjukkan bahwa Adam merupakan *optimizer* yang paling optimal dalam meningkatkan akurasi model dibandingkan dengan RMSprop dan SGD pada skenario yang diuji. Adam memiliki kemampuan adaptif dalam menyesuaikan *learning rate* untuk setiap parameter, sehingga dapat mempercepat konvergensi model dan mengurangi kemungkinan *overfitting* atau *underfitting*. Oleh karena itu, penggunaan *optimizer* Adam dengan *learning rate* 0.001 dapat menjadi pilihan terbaik dalam penerapan CNN untuk deteksi penyakit tanaman anggur, memberikan solusi yang lebih akurat, efisien, dan cepat bagi petani dalam pengelolaan tanaman anggur mereka.

4. Kesimpulan

Penelitian ini membandingkan kinerja *optimizer* RMSprop, Adam, dan SGD dalam mengoptimalkan model DenseNet-121 menggunakan *Transfer Learning* untuk klasifikasi penyakit daun anggur. Dengan variasi *learning rate* 0.1, 0.001, dan 0.00001 selama 20 *epoch*, hasil pengujian menunjukkan bahwa *optimizer* Adam dengan *learning rate* 0.001 menghasilkan akurasi tertinggi, yaitu 99.45%, sedikit lebih unggul dibandingkan RMSprop (99.39%) dan SGD.

Evaluasi *Confusion Matrix* menunjukkan bahwa sebagian besar sampel diklasifikasikan dengan benar, meskipun terdapat beberapa kesalahan antara kelas "Grape_Black_rot" dan "Grape_Esca_(Black_Measles)" karena kemiripan fitur visual. Sementara itu, kelas "Grape_Leaf_blight_(Isariopsis_Leaf_Spot)" dan "Grape_healthy" diklasifikasikan tanpa kesalahan. Dengan hasil ini, Adam dengan *learning rate* 0.001 terbukti sebagai pilihan terbaik untuk meningkatkan akurasi model dalam deteksi penyakit tanaman anggur.

DAFTAR PUSTAKA

- [1] R. Apriyanto dan Moh. Ahsan, "SISTEM ANALISIS DIAGNOSA PENYAKIT TANAMAN ANGGUR DENGAN PENDEKATAN CERTAINTY FACTOR BERBASIS ANDROID," *Kurawal - Jurnal Teknologi, Informasi dan Industri*, vol. 2, no. 1, 2019, doi: 10.33479/kurawal.v2i1.214.
- [2] Ignatius Juan Hartantiko, R. K. Niswatin, dan A. B. Setiawan, "Identifikasi Gejala Dan Penyakit Pada Tanaman Anggur Dengan Metode Forward Chaining Dan Backward

- Chaining,” *Nusantara of Engineering (NOE)*, vol. 6, no. 2, 2023, doi: 10.29407/noe.v6i2.20802.
- [3] K. R. Wardani dan L. Leonardi, “Klasifikasi Penyakit pada Daun Anggur menggunakan Metode Convolutional Neural Network,” *Jurnal Tekno Insentif*, vol. 17, no. 2, 2023, doi: 10.36787/jti.v17i2.1130.
- [4] J. R. Aisyah dan A. Prasetyadi, “Klasifikasi Penyakit Daun Kentang dengan Metode CNN dan RNN,” *Jurnal Tekno Insentif*, vol. 17, no. 1, 2023, doi: 10.36787/jti.v17i1.888.
- [5] A. D. Nurcahyati, R. M. Akbar, dan S. Zahara, “Klasifikasi Citra Penyakit pada Daun Jagung Menggunakan Deep Learning dengan Metode Convolution Neural Network (CNN),” *SUBMIT: Jurnal Ilmiah Teknologi Informasi dan Sains*, vol. 2, no. 2, 2022, doi: 10.36815/submit.v2i2.1877.
- [6] M. Sholikhin dan R. Alexandro H., “Klasifikasi Penyakit pada Citra Daun Melon Menggunakan Algoritma Convolution Neural Network,” *Joutica*, vol. 7, no. 1, 2022, doi: 10.30736/jti.v7i1.735.
- [7] N. B. Pamungkas dan A. Suhendar, “Penerapan Metode Convolutional Neural Network pada Sistem Klasifikasi Penyakit Tanaman Apel berdasarkan Citra Daun,” *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 2, hlm. 675–684, 2024.
- [8] M. Yusuf, D. Kurniawan, T. Agustin, dan others, “Klasifikasi Penyakit Tanaman Jagung dengan Kecerdasan Buatan Berbasis CNN,” dalam *Prosiding Seminar Nasional Amikom Surakarta*, 2024, hlm. 355–368.
- [9] E. Hassan, M. Y. Shams, N. A. Hikail, dan S. Elmougy, “The effect of choosing optimizer algorithms to improve computer vision tasks: a comparative study,” *Multimed Tools Appl*, vol. 82, no. 11, 2023, doi: 10.1007/s11042-022-13820-0.
- [10] M. Reyad, A. M. Sarhan, dan M. Arafah, “A modified Adam algorithm for deep neural network optimization,” *Neural Comput Appl*, vol. 35, no. 23, 2023, doi: 10.1007/s00521-023-08568-z.
- [11] C. Desai, “Comparative Analysis of Optimizers in Deep Neural Networks,” *Int J Innov Sci Res Technol*, vol. 5, no. 10, 2020.
- [12] M. A. Zia, A. Akram, I. Mumtaz, M. A. Saleem, dan M. Asif, “Analysis of grape leaf disease by using deep convolutional neural network,” *Agricultural Sciences Journal*, vol. 5, no. 1, hlm. 25–36, 2023.
- [13] I. M. Esa Darmayasa Adi Putra, I. Fauzi, K. S. Krishna Prasad, K. S. Krishna Prasad, I. M. Putra Arya Winata, dan I. W. Widhiada, “Evaluasi Model Machine Learning Klasifikasi Gerak Tangan Untuk Sistem Kontrol Prototipe Protesis Tangan,” *Majalah Ilmiah Teknologi Elektro*, vol. 22, no. 1, 2023, doi: 10.24843/mite.2023.v22i01.p18.

- [14] S. A. Albelwi, "Deep Architecture based on DenseNet-121 Model for Weather Image Recognition," *International Journal of Advanced Computer Science and Applications*, vol. 13, no. 10, 2022, doi: 10.14569/IJACSA.2022.0131065.
- [15] L. Listyalina, I. Buyung, A. Q. Munir, I. Mustiadi, dan D. A. Dharmawan, "Conv-Tire: Tire Condition Assessment using Convolutional Neural Networks," *Telematika*, vol. 19, no. 3, 2022, doi: 10.31315/telematika.v19i3.7697.
- [16] R. A. Mas' ud dan J. Zeniarja, "Optimasi Convolutional Neural Networks untuk Deteksi Kanker Payudara menggunakan Arsitektur DenseNet," *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 1, hlm. 310–318, 2024.
- [17] E. Y. Prastowo, "Pengenalan Jenis Kayu Berdasarkan Citra Makroskopik Menggunakan Metode Convolutional Neural Network," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 7, no. 2, Agu 2021, doi: 10.28932/jutisi.v7i2.3706.
- [18] A. Kurniasari, D. Erwanto, dan P. N. Rahayu, "Ekstraksi Fitur Tekstur dan Warna pada Kulit Katak Menggunakan GLCM dan Momen Warna," *Jurnal ELTIKOM*, vol. 6, no. 1, 2022, doi: 10.31961/eltikom.v6i1.287.