Ref : 015/UMA/JITE/IV/2025
Subject : Letter of Acceptance

Medan, 21 April 2025

To :
Mr./Mrs. **MHD. Fajar Alry Fadli**

Assalamu'alaikum Wr. Wb

We would like to express our sincere gratitude for your participation in submitting an article to the Journal of Informatics and Telecommunication Engineering (JITE). We hereby inform you that the article listed below:

Paper : Peningkatan Akurasi Deteksi Penyakit Daun Kopi Menggunakan Squeezenet Dan Simam

Author : MHD. Fajar Alry Fadli

Based on the review results, we are pleased to inform you that your submitted article has been ACCEPTED for publication in JITE Journal - **Special Issues 2025: Innovations in Predictive Analytics and Sentiment Analysis - Applications in Education, Healthcare, and Social Media**, ISSN: 2549-6247 (Print) ISSN: 2549-6255 (Online).

We would like to thank you for your attention and cooperation.

Wassalamu'alaikum, Wr.Wb.

Best Regards,

Muhathir, ST., M.Kom
Chief Editor

JITE (Journal of Informatics and Telecommunication Engineering)

Available online <http://ojs.uma.ac.id/index.php/jite> DOI: 10.31289/jite.vxiv.xxx

Received: dd-mm-yyyy

Accepted: dd-mm-yyyy

Published: dd-mm-yyyy

PENINGKATAN AKURASI DETEKSI PENYAKIT DAUN KOPI MENGUNAKAN SQUEEZENET DAN SIMAM

MHD. Fajar Alry Fadli¹⁾, Muhathir²⁾

1) Teknik Informatika, Fakultas Teknik, Universitas Medan Area, Indonesia

2) Teknik Informatika, Fakultas Teknik, Universitas Medan Area, Indonesia

*Corresponding Email:

Abstrak

Deteksi dini terhadap penyakit daun kopi seperti leaf rust dan Phoma sangat penting karena berdampak langsung pada produktivitas dan kualitas hasil panen. Penelitian terbaru menunjukkan bahwa arsitektur CNN ringan seperti SqueezeNet cukup efektif untuk diterapkan pada perangkat dengan keterbatasan komputasi, namun masih memiliki keterbatasan dalam hal akurasi untuk klasifikasi penyakit yang kompleks. Penelitian ini bertujuan untuk meningkatkan akurasi klasifikasi penyakit daun kopi dengan menggabungkan arsitektur SqueezeNet dan modul perhatian SimAM yang mampu memperkuat representasi fitur penting tanpa menambah kompleksitas model secara signifikan. Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental, memanfaatkan dataset citra daun kopi dari sumber terbuka yang telah melalui proses augmentasi dan dibagi menjadi tiga kelas: daun sehat, leaf rust, dan Phoma. Evaluasi model dilakukan dengan metrik akurasi, presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa integrasi SimAM ke dalam SqueezeNet meningkatkan akurasi dari 81% menjadi 84%. Peningkatan performa paling signifikan ditemukan pada kelas leaf rust dan Phoma dengan peningkatan F1-score masing-masing dari 0,70 ke 0,79 dan dari 0,73 ke 0,76. Selain itu, nilai AUC juga meningkat menjadi 0,91. Dengan demikian, integrasi SimAM terbukti efektif dalam meningkatkan performa klasifikasi, meskipun masih terdapat tantangan dalam membedakan kelas dengan fitur visual yang serupa. Penelitian selanjutnya disarankan untuk menerapkan augmentasi data yang lebih agresif dan teknik regularisasi guna meningkatkan kemampuan generalisasi model.

Kata Kunci: Deteksi penyakit daun kopi, SqueezeNet, SimAM, klasifikasi citra, CNN.

Abstract

Early detection of coffee leaf diseases such as leaf rust and Phoma is essential due to its direct impact on crop productivity and quality. Recent studies have shown that lightweight CNN architectures like SqueezeNet are effective for deployment on resource-constrained devices, though they still face limitations in classification accuracy for complex disease types. This study aims to improve the accuracy of coffee leaf disease classification by integrating the SqueezeNet architecture with the SimAM attention module, which enhances feature representation without significantly increasing model complexity. A quantitative experimental approach was used, employing an open-source dataset of coffee leaf images that was augmented and categorized into three classes: healthy leaves, leaf rust, and Phoma. The models were evaluated using accuracy, precision, recall, and F1-score metrics. Results show that integrating SimAM into SqueezeNet increased the model's accuracy from 81% to 84%. The most significant improvements were observed in the leaf rust and Phoma classes, with F1-scores rising from 0.70 to 0.79 and from 0.73 to 0.76, respectively. Additionally, the AUC score improved to 0.91. These results demonstrate that SimAM integration effectively enhances classification performance, though challenges remain in distinguishing classes with visually similar features. Further research is recommended to implement more aggressive data augmentation and regularization techniques to improve model generalization.

Keywords: Coffee leaf disease detection, SqueezeNet, SimAM, image classification, CNN

How to Cite: Pertama, N.P. Pertama, P. & Ketiga, P. (2021). Judul Hendaknya Ringkas dan Informatif Tidak Lebih dari 15 Kata. *JITE (Journal Of Informatics And Telecommunication Engineering)*. 4 (2): 1-10

I. PENDAHULUAN

Kopi merupakan salah satu komoditas pertanian unggulan yang memiliki nilai ekonomi tinggi, terutama di negara-negara penghasil kopi seperti Indonesia (Paminto et-al., 2024). Namun, produktivitas tanaman kopi sering kali terhambat oleh berbagai penyakit daun yang dapat menurunkan hasil panen secara signifikan (Arifin et-al., 2024). Penyakit seperti karat daun (*Hemileia vastatrix*), bercak coklat, dan antraknosa merupakan beberapa contoh yang sering menyerang tanaman kopi (Lesta, 2024). Deteksi dini terhadap penyakit ini sangat penting untuk mengurangi dampak negatif dan meningkatkan kualitas serta kuantitas hasil panen (Farij Amrulloh et-al., 2024).

SqueezeNet merupakan arsitektur jaringan saraf konvolusional (CNN) yang dirancang untuk memiliki ukuran model yang kecil namun tetap mempertahankan akurasi yang kompetitif (Harahap et-al., 2024). SqueezeNet dikembangkan oleh tim peneliti dari DeepScale, UC Berkeley, dan Stanford University pada tahun 2016. Model ini dirancang oleh Forrest N. Iandola, Song Han, Matthew W. Moskewicz, Khalid Ashraf, William J. Dally, dan Kurt Keutzer untuk menciptakan arsitektur CNN yang lebih ringan dengan jumlah parameter yang jauh lebih kecil dibandingkan model lain, seperti AlexNet, tetapi tetap mempertahankan akurasi yang kompetitif (Verdhan, 2021).

SqueezeNet digunakan dalam berbagai bidang visi komputer, terutama untuk aplikasi yang membutuhkan model ringan dan efisien (Ayu & Pradipta, 2024). Dalam klasifikasi gambar, model ini membantu mengenali objek seperti produk e-commerce, tanaman, atau makanan, sehingga cocok untuk aplikasi berbasis AI di perangkat mobile (Ayu & Pradipta, 2024). Dalam deteksi dan pengenalan wajah, SqueezeNet sering diterapkan pada sistem keamanan, seperti akses kontrol dan absensi otomatis, karena dapat dijalankan di perangkat kecil seperti kamera CCTV pintar (Armiady, 2021).

Dalam deteksi objek pada perangkat terbatas, SqueezeNet banyak digunakan pada drone, kamera pengawas, dan sistem pemantauan otomatis (Ihsan Muttaqin et-al., 2023). Contohnya termasuk mendeteksi kendaraan di lalu lintas, mengenali hewan dalam penelitian ekologi, dan memantau pertanian dengan drone (Wijanarko et-al., 2024). Di bidang kesehatan, model ini membantu menganalisis gambar medis, seperti mendeteksi kanker kulit atau pneumonia dari rontgen, serta dapat diterapkan pada perangkat medis portabel yang digunakan di lingkungan dengan sumber daya terbatas (Queentinela & Triyani, 2021).

Dalam kendaraan otonom dan robotika, SqueezeNet berguna untuk mengenali objek di sekitar, seperti rambu lalu lintas, pejalan kaki, dan kendaraan lain, serta membantu robot industri dalam mendeteksi dan mengklasifikasikan produk (Andi Dipayana et-al., 2022). Selain itu, dalam sistem keamanan dan pengawasan, model ini digunakan untuk menganalisis video secara real-time guna mendeteksi aktivitas mencurigakan atau objek berbahaya (Anugrah, 2024). Dengan ukurannya yang kecil dan efisiensi tinggi, SqueezeNet menjadi pilihan ideal untuk AI di perangkat mobile, sistem keamanan, dan lingkungan dengan keterbatasan daya komputasi (Purwanto & Sumardi, 2022).

Walaupun hasil dari berbagai penelitian sudah mencapai hasil yang memuaskan akan tetapi SqueezeNet masih perlu dimodifikasi untuk mencapai hasil yang lebih maksimal (Umri et-al., 2021). Salah satu caranya adalah dengan menambahkan modul perhatian dalam SqueezeNet, modul perhatian juga telah banyak diteliti sebelumnya seperti, Spatial Attention Modul (SimAm), CBAM, SE (Squeeze-and-Excitation) Module, ECA (Efficient Channel Attention), BAM (Bottleneck Attention Module), SKNet (Selective Kernel Networks) (You et-al., 2023). Dalam penelitian ini SimAm menjadi pilihan sebagai modul perhatian yang ditambahkan kedalam arsitektur SqueezeNet, dengan pemilihan SimAM dalam SqueezeNet didasarkan pada kemampuannya meningkatkan ekstraksi fitur tanpa menambah kompleksitas model (Yolovn, 2025). Dengan menganalisis hubungan antar-neuron, SimAM membantu model lebih fokus pada fitur penting untuk membedakan daun kopi sehat dan yang terinfeksi (Maulana, 2024). Tidak seperti modul atensi lain, SimAM bekerja efisien tanpa menambah banyak parameter, sesuai dengan karakteristik SqueezeNet yang ringan dan hemat komputasi. Integrasi ini meningkatkan akurasi deteksi penyakit tanpa memperbesar ukuran model, serta memungkinkan penerapan pada perangkat terbatas seperti smartphone, sehingga mendukung deteksi cepat dan efektif di lapangan (Maiti et-al., 2024).

SimAm juga telah banyak diteliti sebelumnya dengan menerapkan pada metode YOLOv8-SimAm dengan akurasi 95,8%. Pada penerapan yang lainnya SimAm diteliti menggunakan metode MnasNet-SimAm dengan Tingkat akurasi 95,14% (Wen et-al., 2024).

Berdasarkan keunggulan arsitektur SqueezeNet dan ketangguhan modul SimAm maka dalam penelitian ini akan menguji coba menyisipkan SimAm kedalam SqueezeNet untuk mendeteksi penyakit daun kopi .

II. METODE PENELITIAN

A. Alur Penelitian

Langkah penelitian yang dimodelkan dalam penelitian ini diilustrasikan pada gambar 1.

Gambar 1 Kerangka Penelitian

Penelitian ini diawali dengan pengumpulan data yang kemudian melalui tahap pra-pemrosesan untuk memastikan kualitasnya. Data yang telah siap dibagi menjadi tiga bagian: training, validation, dan testing set. Selanjutnya, dua model deep learning, SqueezeNet dan SimAm, dikembangkan dan dilatih menggunakan training set. Setelah proses training, dilakukan evaluasi akurasi dengan validation set untuk mengukur performa awal model.

Setelah model dilatih, tahap evaluasi dilakukan menggunakan testing set untuk mengukur performa akhir dan membandingkan kedua model. Model terbaik kemudian diintegrasikan ke dalam aplikasi berbasis web agar lebih mudah digunakan. Dengan selesainya pengembangan web, penelitian ini menghasilkan sistem yang siap diterapkan untuk mendukung pengguna dalam memanfaatkan model yang telah dikembangkan.

B. Dataset

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh secara tidak langsung, yaitu dari sumber yang sudah ada. Dalam penelitian ini, data sekunder yang berupa citra atau gambar diambil dari sumber terbuka <https://data.mendeley.com/datasets/k36wnd6knb/1>. Pada situs tersebut terdapat tiga kelas jenis penyakit daun kopi yang digunakan, yaitu Health leaves, leaf rust, dan phoma.

C. Augmentasi Data

Penelitian ini menggunakan 3.322 gambar penyakit daun kopi sebagai data, yang dibagi menjadi tiga bagian yaitu data training, data testing, dan data validasi. Sampel gambar penyakit daun kopi tersebut terdiri dari 80% data training, 10% data testing, dan 10% data validasi.

Tabel 1 Pembagian Dataset

No	Kelas	Dataset		
		Training 80%	Testing 10%	Validasi 10%
1	Health Leave	800	100	100
2	Leaf Rust	800	100	100
3	Phoma	800	100	100

D. Rancangan Arsitektur

Gambar 2 Arsitektur SqueezeNet dengan SimAm

Arsitektur yang ditampilkan dalam gambar merupakan modifikasi dari SqueezeNet dengan integrasi SimAM (Similarity Attention Module) untuk meningkatkan efisiensi dan akurasi dalam ekstraksi fitur. Proses diawali dengan lapisan konvolusi pertama (Conv1) yang bertugas mengekstrak fitur dasar dari citra input, diikuti oleh Maxpooling untuk mengurangi dimensi spasial. Setelah itu, jaringan melewati beberapa Fire Modules (Fire2 hingga Fire9), yang terdiri dari lapisan squeeze dan expand untuk mengolah fitur dengan jumlah parameter yang lebih sedikit namun tetap mempertahankan kompleksitas representasi.

Setiap Fire Module diikuti oleh SimAM, sebuah mekanisme perhatian yang membantu model dalam memilih fitur yang lebih relevan berdasarkan hubungannya spasialnya. Penambahan SimAM bertujuan untuk meningkatkan daya representasi fitur tanpa menambah jumlah parameter secara signifikan. Setelah Fire4, dilakukan Maxpooling untuk menurunkan dimensi lebih lanjut, kemudian dilanjutkan dengan Fire5 hingga Fire9. Sebelum tahap akhir, dilakukan konvolusi pada Conv10, yang kemudian diteruskan ke Global Average Pooling untuk mengubah fitur spasial menjadi vektor satu dimensi. Akhirnya, lapisan Softmax digunakan untuk mengubah hasil akhir menjadi probabilitas yang digunakan dalam klasifikasi.

E. Evaluasi

Evaluasi model klasifikasi penyakit daun kopi menampilkan tiga metrik evaluasi yang sering digunakan dalam analisis klasifikasi biner, yaitu accuracy, precision, dan recall. Masing-masing metrik ini memiliki peran penting dalam mengukur performa suatu model klasifikasi. Accuracy dihitung dengan rumus $(TP+TN)/(TP+FP+TN+FN)$, di mana TP (True Positive) merupakan jumlah prediksi positif yang benar, TN (True Negative) adalah jumlah prediksi negatif yang benar, FP (False Positive) mencakup jumlah prediksi positif yang keliru, dan FN (False Negative) merupakan jumlah prediksi negatif yang seharusnya positif. Accuracy digunakan untuk mengevaluasi proporsi prediksi yang benar dibandingkan dengan seluruh prediksi. Namun, metrik ini dapat memberikan gambaran yang bias ketika data bersifat tidak seimbang, seperti pada kasus di mana jumlah data negatif jauh lebih banyak dibandingkan dengan data positif.

Selain itu, metrik precision dihitung dengan rumus $TP/(TP+FP)$, yang berfungsi untuk mengukur akurasi prediksi positif. Precision mencerminkan sejauh mana prediksi positif yang dibuat oleh model sesuai dengan kondisi sebenarnya. Metrik ini menjadi krusial ketika False Positive perlu diminimalkan, misalnya dalam konteks deteksi spam, di mana prediksi positif yang salah dapat mengganggu pengguna. Di sisi lain, recall, yang dihitung menggunakan rumus $TP/(TP+FN)$, mengukur kemampuan model dalam mendeteksi seluruh sampel positif yang ada. Recall sangat relevan dalam situasi di mana False Negative perlu ditekan, seperti dalam deteksi penyakit serius, di mana kegagalan mendeteksi kasus positif dapat menimbulkan konsekuensi berbahaya. Dengan memahami dan mengaplikasikan metrik ini secara tepat, peneliti dan praktisi dapat melakukan evaluasi performa model secara lebih komprehensif sesuai dengan tujuan analisis dan karakteristik dataset yang digunakan.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

III. HASIL DAN PEMBAHASAN

A. Hasil

Dalam penelitian ini, beberapa prosedur diterapkan pada klasifikasi daun kopi. Selama fase pemrosesan data, catatan data dibagi menjadi tiga bagian utama: 80% dalam pelatihan, 10% dalam tes, dan 10% dalam validasi. Selain itu, formalisasi data dilakukan untuk mengubah variabel numerik menjadi format yang memenuhi persyaratan model, memastikan penskalaan data yang seragam dan dapat diproses secara optimal dengan algoritma pembelajaran mesin. Setelah tingkat normalisasi, dipilih model transfer learning, yaitu SqueezeNet dengan SimAm untuk meningkatkan efisiensi klasifikasi. Selain itu, ekspansi data dilakukan dengan mengubah ukuran gambar menjadi 22 x 22 dan 128 x 128 piksel untuk meningkatkan kemampuan generalisasi model. Setelah menyelesaikan semua fase ini, proses ini mengikuti fase pengujian model untuk menilai kinerja dalam deteksi penyakit daun kopi.

Berikut merupakan evaluasi rata-rata keseluruhan model:

Tabel 2 Evaluasi Model

Model	Jumlah Parameter
SqueezeNet	1,235,496
SqueezeNet dan SimAm	1,235,496

Gambar 3 Grafik SqueezeNet

Gambar 3 menampilkan grafik kinerja model selama 20 epoch pelatihan, yang mencakup nilai loss dan akurasi pada data pelatihan serta validasi. Terlihat bahwa training loss menurun secara konsisten, sedangkan validation loss justru meningkat dan menunjukkan fluktuasi, mengindikasikan terjadinya overfitting. Hal ini diperkuat oleh grafik akurasi, di mana akurasi pelatihan meningkat tajam hingga hampir sempurna, sementara akurasi validasi cenderung stagnan dan menurun pada beberapa titik. Perbedaan signifikan antara performa model pada data pelatihan dan validasi menunjukkan bahwa model terlalu menyesuaikan diri terhadap data pelatihan dan gagal mengeneralisasi ke data baru. Kondisi ini kemungkinan disebabkan oleh kompleksitas model yang tinggi, kurangnya penerapan regularisasi, terbatasnya jumlah data, atau belum optimalnya teknik augmentasi data yang digunakan.

Gambar 4 Grafik SqueezeNet dengan SimAm

Gambar 4 memperlihatkan dua grafik yang menggambarkan performa model selama 20 epoch pelatihan, berdasarkan nilai loss dan akurasi. Pada grafik kiri, training loss menunjukkan penurunan yang konsisten hingga mendekati nol, yang menandakan bahwa model mampu mengenali pola-pola pada data

pelatihan dengan sangat baik. Sebaliknya, validation loss terlihat tidak stabil dan mengalami fluktuasi yang cukup signifikan, mencerminkan ketidakmampuan model dalam melakukan generalisasi terhadap data validasi. Grafik kanan menunjukkan bahwa akurasi pada data pelatihan terus meningkat dan hampir mencapai 100%, sementara akurasi pada data validasi cenderung naik turun tanpa pola peningkatan yang jelas, berkisar antara 65% hingga 95%. Ketimpangan antara performa model pada data pelatihan dan validasi mengindikasikan terjadinya overfitting, yaitu kondisi di mana model terlalu terpaku pada data pelatihan sehingga tidak mampu memberikan prediksi yang baik pada data baru. Hal ini dapat terjadi akibat kompleksitas model yang tinggi, keterbatasan jumlah data, kurangnya augmentasi, atau absennya teknik regularisasi yang memadai.

Gambar 5 Matrix (a) SqueezeNet (b) dengan SimAm

Gambar 5(a) menunjukkan matriks kebingungan (confusion matrix) yang digunakan untuk mengevaluasi kinerja model klasifikasi terhadap tiga kelas: daun sehat (healthy leaves), leaf rust, dan phoma. Dari hasil prediksi, model mampu mengklasifikasikan seluruh data daun sehat dengan benar sebanyak 180 sampel tanpa kesalahan. Namun, untuk kelas leaf rust, terdapat 120 prediksi yang benar, sementara 5 sampel salah diklasifikasikan sebagai daun sehat dan 55 lainnya keliru diprediksi sebagai phoma. Adapun untuk kelas phoma, model mengklasifikasikan 135 sampel dengan benar, tetapi 43 sampel salah dikenali sebagai leaf rust dan 2 lainnya sebagai daun sehat. Matriks ini menunjukkan bahwa meskipun model sangat akurat dalam mengenali daun sehat, masih terdapat kesalahan yang cukup signifikan dalam membedakan antara penyakit leaf rust dan phoma, yang mengindikasikan bahwa kedua kelas tersebut memiliki karakteristik visual yang mirip sehingga menyulitkan proses klasifikasi.

Gambar 5(b) merupakan matriks kebingungan yang digunakan untuk mengevaluasi performa model klasifikasi terhadap tiga kelas, yaitu daun sehat (healthy leaves), leaf rust, dan phoma. Berdasarkan matriks, model berhasil mengklasifikasikan 173 sampel daun sehat dengan benar, sementara 7 sampel sehat salah diklasifikasikan sebagai phoma. Untuk kelas leaf rust, sebanyak 151 sampel berhasil dikenali dengan tepat, namun 4 sampel keliru diklasifikasikan sebagai daun sehat dan 25 sampel sebagai phoma. Adapun pada kelas phoma, 129 sampel terklasifikasi dengan benar, sedangkan 51 sampel salah dikenali sebagai leaf rust. Secara keseluruhan, model menunjukkan performa klasifikasi yang cukup baik, terutama pada kelas daun sehat dan leaf rust, namun masih terdapat tingkat kesalahan yang cukup tinggi dalam membedakan antara leaf rust dan phoma, yang mengindikasikan adanya kemiripan fitur visual antara kedua jenis penyakit tersebut.

Gambar 6 ROC AUC (a) SqueezeNet (b) dengan SimAm

Gambar 6(a) menunjukkan kurva ROC untuk tiga kelas daun kopi: Health leaves, leaf rust, dan phoma. Kurva ini menggambarkan kemampuan model dalam membedakan masing-masing kelas berdasarkan nilai True Positive Rate dan False Positive Rate. Nilai AUC tertinggi terdapat pada Health leaves (1.00), menunjukkan klasifikasi sempurna, sementara leaf rust dan phoma memiliki AUC masing-masing 0.87 dan 0.88, menandakan performa klasifikasi yang baik namun belum sempurna.

Gambar 6(b) menyajikan kurva ROC untuk tiga kelas daun kopi: Health leaves, leaf rust, dan phoma. Kurva ini menggambarkan kinerja model dalam membedakan masing-masing kelas berdasarkan hubungan antara True Positive Rate dan False Positive Rate. Nilai AUC yang tercantum menunjukkan tingkat akurasi model dalam klasifikasi. Kelas Health leaves memiliki AUC sebesar 1.00, menandakan klasifikasi sempurna. Sedangkan kelas leaf rust dan phoma masing-masing memiliki AUC sebesar 0.92 dan 0.91, yang menunjukkan bahwa model mampu mengklasifikasikan kedua kelas tersebut dengan akurasi tinggi.

Gambar 7 Grafik ROC AUC Semua Model

Gambar 7 menggambarkan performa dari semua model yang diuji dalam penelitian ini ROC AOC digunakan untuk menilai kemampuan model dalam membedakan antara kelas positif dan negatif di setiap model.

Berikut merupakan tabel evaluasi dengan classification report SqueezeNet dengan SimAM

Tabel 3 Classification report

Model	Kelas	Precision	Recall	F1-Score	Support
SqueezeNet	Health leaves	0.96	1.00	0.98	180
	Leaf rust	0.74	0.67	0.70	180
	Phoma	0.71	0.75	0.73	180
	Accuracy			0.81	540
	Macro avg	0.80	0.81	0.81	540
	Weighted avg	0.80	0.81	0.80	540
SqueezeNet dengan SimAm	Health leaves	0.98	0.96	0.97	180
	Leaf rust	0.75	0.84	0.79	180
	Phoma	0.80	0.72	0.76	180
	Accuracy			0.84	540
	Macro avg	0.84	0.84	0.84	540
	Weighted avg	0.84	0.84	0.84	540

B. Pembahasan

Hasil evaluasi menunjukkan menyajikan perbandingan kinerja antara model SqueezeNet dan SqueezeNet yang dilengkapi dengan modul Simple Attention (SimAm) dalam klasifikasi citra daun kopi berdasarkan tiga kategori, yakni health leaves, leaf rust, dan Phoma. Hasil evaluasi menunjukkan bahwa penambahan modul SimAm mampu meningkatkan performa model, terutama pada kelas penyakit yang sebelumnya memiliki tingkat akurasi rendah. Meskipun kedua model menunjukkan hasil yang sangat baik pada kelas daun sehat, peningkatan F1-score terlihat signifikan pada kelas karat daun (dari 0,70 menjadi 0,79) dan kelas Phoma (dari 0,73 menjadi 0,76). Selain itu, akurasi keseluruhan model meningkat dari 0,81 menjadi 0,84, sejalan dengan kenaikan nilai macro average dan weighted average menjadi 0,84. Hal ini mengindikasikan bahwa penerapan modul perhatian sederhana seperti SimAm tidak hanya meningkatkan akurasi, tetapi juga memperbaiki keseimbangan performa antar kelas, sehingga model menjadi lebih andal dalam mengidentifikasi berbagai kondisi daun kopi, termasuk yang memiliki karakteristik visual yang lebih kompleks.

Berikut tabel hasil perbandingan penelitian sebelumnya dengan penelitian ini.

Tabel 4 Hasil Evaluasi Penelitian Sebelumnya dan Penelitian Ini

referensi	model	dataset	akurasi	precision	recall	F1-score
(FIBRIANI, 2020)	Euclidean Distance dan Hough Transform	Daun Kopi Arabika dan Robusta	55%	-	-	-
(Wildah et al., 2024)	Generative Adversarial Network	Daun Kopi: Rust dan Miner	0.1658	-	-	-
(Murni et al., 2022)	Support Vector Machine (SVM)	Daun Kopi Arabika: Leaf Miner, Leaf Rust, Phoma, Cercospora, Healthy	68,30%	55,77%	57,85%	-
Penelitian Ini	SqueezeNet + SimAm	Daun Kopi: Health Leave, Leaf Rust, Phoma	84%	84%	84%	84%

IV. SIMPULAN

Penelitian ini menunjukkan bahwa integrasi modul perhatian SimAM ke dalam arsitektur SqueezeNet mampu meningkatkan akurasi klasifikasi penyakit daun kopi dari 81% menjadi 84%, terutama pada kelas leaf rust dan Phoma yang sebelumnya sulit dibedakan. Temuan ini membuktikan bahwa pendekatan perhatian spasial dapat meningkatkan kualitas representasi fitur tanpa menambah kompleksitas model secara signifikan. Model yang dihasilkan ringan dan efisien, sehingga cocok diterapkan pada perangkat mobile atau sistem berbasis IoT di sektor pertanian. Penelitian ini bermanfaat untuk mendukung deteksi dini penyakit tanaman secara cepat dan akurat. Sebagai rekomendasi, peneliti selanjutnya disarankan untuk menerapkan teknik augmentasi data yang lebih variatif, menggunakan regularisasi seperti dropout untuk mengurangi overfitting, serta mengembangkan implementasi model dalam bentuk aplikasi lapangan guna menguji performa di kondisi nyata.

DAFTAR PUSTAKA

- Andi Dipayana, I. G. M., Care Khrisne, D., & Setiawan, W. (2022). Rancang Bangun Alat Monitoring Tanaman Hidroponik Pakcoy Memanfaatkan Mikrokontroler Dan Teknik Computer Vision. *Jurnal SPEKTRUM*, 9(1), 19. <https://doi.org/10.24843/spektrum.2022.v09.i01.p3>
- Anugrah, M. D. (2024). *Peran Teknologi AI dalam Mengembangkan Algoritma Media Sosial : Tantangan dan Peluangnya*. 3(2), 80–105.
- Arifin, M., Solihin, M. A., Devnita, R., Rosniawaty, S., Putri, N., & Ramadhan, I. (2024). SOSIALISASI REKOMENDASI PEMUPUKAN DAN PEMBUATAN NEMATISIDA NABATI DALAM MENINGKATKAN PRODUKTIVITAS TANAMAN KOPI DI DESA CAMPAKAMULYA Mahfud. *Dharmakarya: Jurnal Aplikasi Ipteks untuk Masyarakat*, 13(1), 147–152.
- Armiady, D. (2021). Absensi Kehadiran Menggunakan Kamera Pengawas Berbasis Teknologi Computer Vision. *Jurnal Tika*, 6(02), 140–146. <https://doi.org/10.51179/tika.v6i02.541>
- Ayu, D. W., & Pradipta, G. A. (2024). SqueezeNet Feature Extraction dan Gradient Boosting untuk Klasifikasi Penyakit Monkeypox pada Citra Kulit. *Jurnal Sistem dan Informatika (JSI)*, 18(2), 177–183. <https://doi.org/10.30864/jsi.v18i2.612>
- Farij Amrulloh, M., Pamungkas, D. P., Kunci-Daun Bawang, K., Klasifikasi, ;, Cnn, ;, Xception, ;, & Amrulloh, M. F. (2024). Klasifikasi Penyakit Daun Bawang Menggunakan Algoritma CNN Xception Penulis Korespondensi. *Agustus*, 8, 2549–7952.
- FIBRIANI, I. W. W. S. C. S. D. F. (2020). *F. T_Jurnal_Ike Fibriani_Deteksi Penyakit Brown Eye Spot pada Daun Kopi*.
- Harahap, H., Rahman, S., & Zen, M. (2024). Analisis Existing Convolutional Neural Network Untuk Klasifikasi Usia Pengunjung Rumah Sakit: Studi Kasus Pemantauan Anak dan Dewasa. *Journal of Computer Science and Information Technology E-ISSN*, 4(1), 16.
- Ihsan Muttaqin, M., Stefanie, A., & Nurpulaela, L. (2023). Implementasi Metode Deep Learning Untuk Menentukan Tingkat Kematangan Buah Pepaya California. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(3), 1878–1884. <https://doi.org/10.36040/jati.v7i3.6948>
- Lesta, L. (2024). *Buku Ajar Hama dan Penyakit Tanaman*. Politeknik Manufaktur Negeri Bangka Belitung.
- Maiti, A., Abarda, A., Hanini, M., & Oussous, A. (2024). An Optimal Model Combining SqueezeNet and Machine Learning Methods for Abstract : *Current Medical Imaging*, 20(3), 1–16. <https://doi.org/10.2174/0115734056258742230920062315>

- Maulana, S. (2024). Deteksi Kesegaran Telur Ayam pada Citra Cangkang Menggunakan Metode Convolutional Neural Network (CNN). *JIMU: Jurnal Ilmiah Multi Disiplin*, 2(4), 813–822.
- Murni, S., Widiyanto, D., & Dewi, C. N. P. (2022). Klasifikasi Citra Penyakit Daun Kopi Arabika Menggunakan Support Vector Machine (SVM) Dengan Seleksi Fitur Information Gain. *Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA)*, 700–709.
- Paminto, S. R., Herawati, A., Nabila, B., Aliyatunnisa, N., Putri, R. A., Alhaddi, R. U., Selviana, S., Maharani, S. J., & Maharani, W. P. (2024). Perlindungan Hukum Bagi Pelaku Komiditi Pertanian Menghadapi Krisis Pangan dengan Penguatan Anggaran. *Hukum Inovatif: Jurnal Ilmu Hukum Sosial dan Humaniora*, 1(3), 135–157.
- Purwanto, P., & Sumardi, S. (2022). Perancangan Klasifikasi Tanaman Herbal Menggunakan Transfer Learning Pada Algoritma Convolutional Neural Network (CNN). *Jurnal Ilmiah Infokam*, 18(2), 105–118. <https://doi.org/10.53845/infokam.v18i2.328>
- Queentinela, V. A., & Triyani, Y. (2021). Klasifikasi Penyakit Diabetic Retinopathy Pada Citra Fundus Berbasis Deep Learning. *9th Applied Business and Engineering Conference*, 1, 1–11.
- Umri, B. K., Utami, E., & Kurniawan, M. P. (2021). menggunakan Convolutional Neural Networks Systematic Literature Review of Detection Covid-19 using Convolutional Nerual Networks. *Citec Journal*, 8(1).
- Verdhan, V. (2021). *Computer Vision Using Deep Learning*. Springer.
- Wen, X., Maimaiti, M., Liu, Q., Yu, F., Gao, H., & Li, G. (2024). *MnasNet-SimAM : An Improved Deep Learning Model for the Identification of Common Wheat Diseases in Complex Real-Field Environments*.
- Wijanarko, R. G., Pradana, A. I., & Hartanti, D. (2024). *IMPLEMENTASI DETEKSI DRONE MENGGUNAKAN YOLO (You Only Look Once)*. 14(2), 437–442.
- Wildah, S. K., Latif, A., & Haryanto, T. (2024). SINTESA CITRA DAUN KOPI MENGGUNAKAN GENERATIVE ADVERSARIAL NETWORK PADA DATASET PENYAKIT DAUN KOPI. *INTI NUSA MANDIRI*, 19(1), 23–30.
- Yolovn, R. P. B. (2025). *Penerapan Modul Ghost dan SimAM pada Sistem Guide Following Kursi*. 9(2), 1–5.
- You, H., Lu, Y., & Tang, H. (2023). Plant Disease Classification and Adversarial Attack Using SimAM-EfficientNet and GP-MI-FGSM. *Sustainability (Switzerland)*, 15(2). <https://doi.org/10.3390/su15021233>