

Komparasi Inception-v3 dan Inception-ResNet-v2 pada Citra Mammogram untuk Deteksi Dini Kanker Payudara

Ketrin Vani Andini^{*1}, Habibullah Akbar²

¹Program Studi Teknik Informatika, Universitas Esa Unggul, Jakarta, Indonesia

²Program Studi Magister Ilmu Komputer, Universitas Esa Unggul, Jakarta, Indonesia

Email: ^{*1}ketrinvania@student.esaunggul.ac.id, ²habibullah.akbar@esaunggul.ac.id

(Naskah masuk: 12 Juli 2025, diterima untuk diterbitkan: 19 Juli 2025)

Abstrak: Kanker payudara merupakan penyebab utama kematian terkait kanker pada wanita secara global. Skrining dini berbasis mamogram sangat penting untuk meningkatkan tingkat pemulihan dan hasil kesehatan pasien secara keseluruhan. Studi ini mengevaluasi dan membandingkan kinerja dua arsitektur CNN: Inception-v3 dan Inception-ResNet-v2 untuk mengklasifikasikan gambar mamogram apakah menunjukkan tanda-tanda kanker atau tidak. Dataset terdiri dari 745 gambar (125 gambar kanker dan 620 gambar non-kanker), diubah ukurannya menjadi 299×299 piksel, dan dibagi menjadi 80% untuk pelatihan dan 20% untuk validasi. Kedua model dilatih menggunakan transfer learning dengan bobot pra-latih dari ImageNet serta berbagai konfigurasi hiperparameter. Kinerja terbaik dicapai oleh model Inception-ResNet-v2, yang menggunakan learning rate sebesar 0.1, batch size sebanyak 64, 20 epoch, dan optimizer Adamax. Konfigurasi ini menghasilkan akurasi sebesar 95,30%, presisi 95,39%, recall 95,30%, dan skor F1 sebesar 95,34%, dengan waktu pelatihan selama 5,13 menit. Hasil ini menunjukkan bahwa pemilihan model yang tepat serta hiperparameter yang dioptimalkan secara signifikan meningkatkan kinerja klasifikasi. Penelitian ini memperkuat efektivitas metode pembelajaran mendalam dalam mendukung deteksi dini kanker payudara secara cepat dan akurat melalui analisis citra mamogram.

Kata Kunci – Kanker payudara; Klasifikasi citra mamogram; Inception-v3; Inception-ResNet-v2; Jaringan Saraf Konvolusional.

Comparison of Inception-v3 and Inception-ResNet-v2 on Mammogram Images for Early Breast Cancer Detection

Abstract: Breast cancer is a leading cause of cancer-related mortality among women globally. Mammogram-based early screening is vital in improving recovery rates and overall patient health outcomes. This study evaluates and compares the performance of two CNN architectures: Inception-v3 and Inception-ResNet-v2 for classifying mammogram images as either showing signs of cancer or not. The dataset consists of 745 images (125 cancerous and 620 non-cancerous), resized to 299×299 pixels, and split into 80% training and 20% validation sets. Both models were trained using transfer learning with pretrained ImageNet weights and multiple hyperparameter configurations. The best performance was achieved by the Inception-ResNet-v2 model, which utilized a learning rate of 0.1, a batch size of 64, 20 epochs, and the Adamax optimizer. This configuration resulted in 95.30% accuracy, 95.39% precision, 95.30% recall, and a 95.34% F1-score, with a training time of 5.13 minutes. These results indicate that selecting an appropriate model and optimized hyperparameters significantly enhances classification performance. This research reinforces the effectiveness of deep learning methods in supporting precise and rapid early detection of breast cancer using mammogram image analysis.

Keywords – Breast cancer; Mammogram classification; Inception-v3; Inception-ResNet-v2; Convolutional Neural Network.

1. PENDAHULUAN

Hingga saat ini, kanker payudara masih menjadi ancaman serius yang menimbulkan kekhawatiran besar di kalangan perempuan secara global. Berdasarkan data GLOBOCAN 2022, tercatat lebih dari 670.000 kematian akibat penyakit ini. Deteksi dini melalui pemeriksaan mamografi merupakan metode yang efektif untuk mengurangi tingkat kematian, namun masih menghadapi tantangan dalam akurasi dan ketergantungan pada interpretasi manual oleh ahli

radiologi [1]. Di era digital ini, pengembangan metode deteksi dini kanker payudara yang akurat dan efisien menjadi tantangan sekaligus peluang besar dalam dunia medis. Klasifikasi citra mammogram menggunakan teknik *deep learning* telah diidentifikasi sebagai metode potensial untuk meningkatkan akurasi diagnosis dan menurunkan angka kematian akibat kanker payudara. Melalui penelitian ini, kami berupaya memberikan kontribusi nyata dalam meningkatkan akurasi diagnosis mammogram menggunakan teknologi *deep learning*.

Analisis citra mammografi saat ini dapat diterapkan melalui pemanfaatan arsitektur *Convolutional Neural Networks (CNN)*. *Convolutional Neural Network (CNN)* algoritma *deep learning* yang tersusun dari *neuron-neuron* tiga dimensi yang dibentuk secara berlapis. *Neuron* tersebut direpresentasikan dalam tiga dimensi, yakni dimensi lebar, tinggi, dan kedalaman. CNN memanfaatkan lapisan konvolusi sebagai bagian utama dalam mengekstraksi fitur, dengan cara memproses input citra dengan mengambil informasi dari area kecil dalam citra dan menghitung konvolusi antara area tersebut dan filter atau kernel yang digeser melintasi citra untuk menghasilkan fitur-fitur tertentu[2]. Dengan kemampuannya dalam menangkap detail kompleks pada citra, algoritma ini dapat mendeteksi pola tersembunyi yang sulit dikenali manusia dan digunakan untuk mengklasifikasikan serta mendiagnosis kanker payudara [3].

Kemajuan dalam bidang kecerdasan buatan telah membuka peluang bagi penggunaan metode *deep learning*, di mana CNN menjadi salah satu arsitektur yang paling menjanjikan untuk analisis gambar medis. Model Inception-v3 telah diterapkan dalam penelitian oleh [4] untuk tujuan klasifikasi tumor payudara dan memperoleh akurasi 93%. Sementara itu, [5] menerapkan Inception-ResNet-v2 pada citra USG dan berhasil mencapai akurasi prediksi sebesar 90%. Meskipun hasil tersebut menunjukkan potensi besar CNN dalam meningkatkan akurasi klasifikasi kanker, sebagian besar studi masih menggunakan satu arsitektur tanpa membandingkan performanya secara langsung dalam konteks klasifikasi citra mammogram.

Namun demikian, masih banyak penelitian yang tidak secara eksplisit menjelaskan pengaruh kombinasi parameter pelatihan seperti *learning rate*, *batch size*, jumlah *epoch*, dan jenis *optimizer* terhadap performa klasifikasi. Dengan demikian, fokus dari penelitian ini adalah pada pengembangan serta analisis komparatif terhadap performa dua arsitektur CNN, yakni Inception-v3 dan Inception-ResNet-v2, untuk mengklasifikasikan citra mammogram menjadi kategori kanker dan non-kanker. Penelitian ini juga menganalisis dampak konfigurasi pelatihan terhadap performa model melalui pengukuran performa menggunakan indikator akurasi, presisi, *recall*, *F1-score*, dan efisiensi waktu pelatihan.

2. METODE PENELITIAN

Kami menerapkan pendekatan kuantitatif eksperimental dengan fokus pada perbandingan dua arsitektur CNN yang populer yaitu Inception-v3 dan Inception-ResNet-v2 yang dilatih menggunakan metode *transfer learning* dengan bobot awal dari *ImageNet*.

2.1. Pengumpulan Data

Kami menggunakan dataset '*Mammogram Mastery*' yang berisi 745 citra mammogram dalam format JPG. Dataset ini berasal dari empat rumah sakit di Sulaimani, Irak dan memiliki komposisi yang tidak seimbang (125 citra kanker dan 620 citra non-kanker). Ketidakseimbangan dataset ini sebenarnya mencerminkan kondisi real di lapangan, dimana kasus non-kanker memang lebih banyak ditemukan dibandingkan kasus kanker dalam *screening* mammogram. Seluruh citra telah divalidasi oleh ahli radiologi dan diklasifikasikan ke dalam dua kategori: kanker dan non-kanker. Dataset ini dapat diakses secara publik melalui tautan berikut: <https://data.mendeley.com/datasets/fvjhtskg93/1> [6].

2.2. Data Preprocessing

Sebelum memasukkan data ke model, kami melakukan *preprocessing* terlebih dahulu untuk menyesuaikan dataset dengan *requirement* kedua arsitektur model yang digunakan. *Preprocessing*

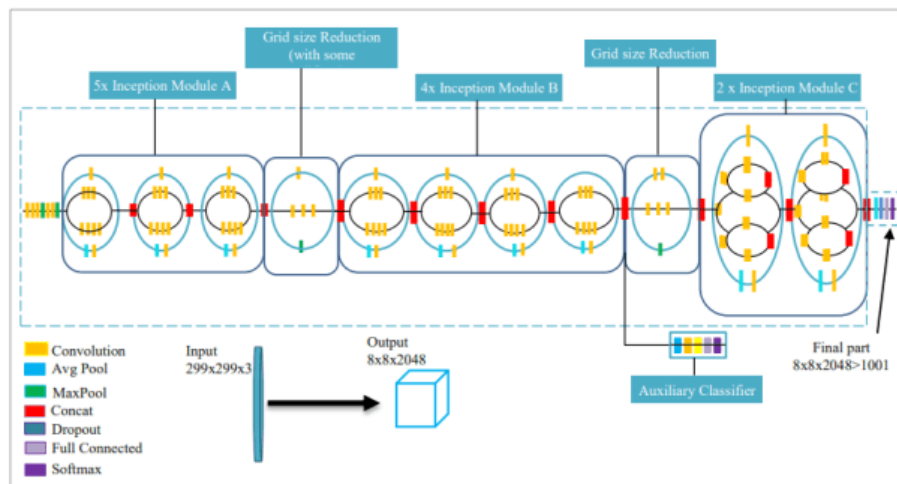
merupakan tahap pendahuluan dalam pengolahan data, di mana data mentah disiapkan agar dapat diproses lebih lanjut [7]. Proses ini penting untuk memastikan input data sesuai dengan spesifikasi Inception-v3 dan Inception-ResNet-v2. Hal ini dilakukan untuk meningkatkan akurasi serta efisiensi dalam klasifikasi kanker payudara menggunakan citra mammogram. Pertama-tama, Seluruh citra diubah ukurannya agar sesuai dengan spesifikasi input yaitu 299×299 piksel untuk disesuaikan dengan arsitektur Inception-v3 dan Inception-ResNet-v2. Kemudian, *scaling* dilakukan untuk mengubah nilai piksel menjadi rentang 0-1 [8]. Selain itu, kami juga menerapkan augmentasi data. Dalam penelitian ini, augmentasi diterapkan pada data pelatihan menggunakan teknik rotasi, *flipping horizontal*, *shifting*, dan *zooming* untuk meningkatkan keragaman data.

2.3. Desain Arsitektur

Proses pengenalan citra berbasis CNN sangat dipengaruhi oleh jenis arsitektur model yang diterapkan. Arsitektur CNN umumnya terdiri dari dua tahapan utama, yaitu lapisan konvolusi yang berfungsi untuk mengekstraksi fitur, dan lapisan jaringan saraf (*Neural Network*) yang bertugas melakukan klasifikasi. Dalam membangun model CNN, berbagai kombinasi *hyperparameter* dapat diterapkan pada lapisan konvolusi maupun lapisan *sub-sampling* untuk meningkatkan performa [9]. Pada penelitian ini, digunakan metode transfer learning untuk melatih model dengan memanfaatkan pretrained model. Berikut adalah penjelasan dari masing-masing arsitektur yang digunakan.

2.3.1. Inception-v3


Arsitektur Inception-v3 adalah sebuah CNN (*Convolutional Neural Network*) dalam yang terdiri dari 42 lapisan, dikembangkan oleh Google, dengan kinerja tinggi dalam klasifikasi citra, dan terdiri dari: lapisan konvolusi, *pooling*, *dropout*, *fully connected*, dan *softmax*, sebagaimana ditampilkan pada Gambar 1 di bawah ini:



Gambar 1. Arsitektur Inception-v3 [10]

2.3.2. Inception-ResNet-v2

Inception-ResNet-v2 (lihat gambar 2) merupakan arsitektur CNN turunan dari keluarga Inception yang dikembangkan dengan menambahkan koneksi residual sebagai pengganti tahapan filter berurutan pada arsitektur Inception [11]. Arsitektur ini menggabungkan konsep Inception yang memungkinkan ekstraksi fitur multi-level dalam satu lapisan dengan *residual connections*, yang membantu mempertahankan informasi penting dan mencegah degradasi gradient.



Gambar 2. Skema *Inception-ResNet-v2*

2.4. Training Model

Proses training model dengan arsitektur Inception-v3 dan Inception-ResNet-v2 menggunakan data training dan data validation. Data validation digunakan untuk mengevaluasi model selama proses pelatihan dan membantu mengukur sejauh mana model bekerja dengan data yang tidak pernah dilihat sebelumnya. Selama pelatihan, fungsi loss yang digunakan adalah Categorical Cross-Entropy Loss. Tujuan pelatihan adalah meminimalkan nilai loss agar hasil prediksi semakin akurat. Formula Categorical Cross-Entropy Loss:

$$L(y, \hat{y}) = - \sum_{i=1}^C y_i \log(\hat{y}_i) \quad (1)$$

Keterangan:

- $L(y, \hat{y})$ adalah *loss categorical cross-entropy*.
- y_i adalah label asli (0 atau 1 untuk setiap kelas) dari vektor target yang berasal dari *one-hot encoder*.
- \hat{y}_i adalah probabilitas prediksi untuk *class i*.
- C adalah jumlah *class*.

Beberapa kombinasi *hyperparameter* diuji untuk memperoleh konfigurasi terbaik. Empat jenis *optimizer* digunakan, yaitu SGD, Adam, Adamax, dan RMSprop, dengan kombinasi nilai *learning rate* sebesar 0.0001 hingga 0.1, ukuran *batch* sebanyak 8, 16, 32, dan 64, serta jumlah *epoch* sebanyak 20, 30, 40, dan 50. Pemilihan keempat *optimizer* ini didasarkan pada perbedaan karakteristiknya dalam mengelola proses pembaruan bobot pada saat pelatihan model berlangsung, serta umum digunakan dalam berbagai studi *deep learning*. Pembagian dataset dilakukan ke dalam dua subset, yakni data dibagi menjadi 80% untuk *training* dan 20% untuk *validation* set guna memastikan evaluasi model secara objektif.

2.5. Evaluasi Model

Evaluasi performa model dilakukan dengan memanfaatkan *confusion matrix* (lihat gambar 3), dengan fokus pada empat metrik utama: akurasi, presisi, *recall*, dan *F1-score*. Akurasi berfungsi untuk menghitung proporsi keseluruhan prediksi yang tepat. Presisi menunjukkan sejauh mana prediksi positif yang dihasilkan oleh model benar-benar tepat, sementara *recall* menilai kemampuan model dalam mendeteksi semua *instance* positif (citra kanker) yang ada. Adapun *F1-score* dihitung

sebagai kombinasi harmonis dari nilai presisi dan recall, sehingga mampu merepresentasikan keseimbangan antara keduanya secara adil, khususnya pada data yang tidak seimbang. Selain sebagai indikator performa, *confusion matrix* dimanfaatkan untuk menganalisis pola kesalahan yang terjadi dalam proses klasifikasi antar kelas. Model terbaik dipilih berdasarkan kombinasi metrik tertinggi dan waktu pelatihan yang efisien. Terdapat beberapa istilah yang ada pada *confusion matrix*, sebagaimana ditampilkan pada Gambar 3 dibawah ini:

		Predicted condition	
		Positive (PP)	Negative (PN)
Actual condition	Total population = P + N		
	Positive (P)	True positive (TP)	False negative (FN)
	Negative (N)	False positive (FP)	True negative (TN)

Gambar 3. Confusion Matrix

dimana:

- TP (True Positive): Citra kanker yang berhasil diklasifikasikan sebagai kanker.
- TN (True Negative): Citra non-kanker yang berhasil diklasifikasikan sebagai non-kanker.
- FP (False Positive): Citra non-kanker yang salah diklasifikasikan sebagai kanker.
- FN (False Negative): Citra kanker yang salah diklasifikasikan sebagai non-kanker.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Eksperimen

Perbandingan performa dilakukan terhadap dua jenis arsitektur dalam *Convolutional Neural Network* (CNN), yakni Inception-v3 dan Inception-ResNet-v2, dalam klasifikasi citra mammogram. Evaluasi terhadap kinerja model dilakukan dengan mengacu pada metrik *accuracy*, *precision*, *recall*, *F1-score*, serta waktu pelatihan (*CPU time*) sebagai indikator efisiensi komputasi. Peneliti melakukan eksplorasi terhadap delapan kombinasi *hyperparameter* yang dipilih dari faktor-faktor utama yang telah dijelaskan pada bagian metode, yaitu *learning rate*, *batch size*, *epoch*, dan *optimizer*. Tujuan eksplorasi ini adalah untuk mengetahui variasi performa dari masing-masing arsitektur CNN dalam klasifikasi citra mammogram. Hasil dari setiap konfigurasi ditampilkan pada Tabel 1.

Tabel 1. Hasil Eksperimen

No	Learning Rate	Batch Size	Epoch	Optimizer	CNN Arsitektur	akurasi	Presisi	Recall	F1 Score	CPU TIME (minutes)
1	0.0001	8	20	SGD	Inception-v3	0.8926	0.8849	0.8926	0.8841	7.87
2	0.0001	16	30	Adam	Inception-ResNet-v2	0.9530	0.9520	0.9530	0.9518	6.04
3	0.001	32	50	SGD	Inception-ResNet-v2	0.9463	0.9450	0.9463	0.9444	20.18
4	0.001	64	40	Adam	Inception-v3	0.9329	0.9379	0.9329	0.9258	7.06
5	0.01	8	40	RMSprop	Inception-ResNet-v2	0.9530	0.9520	0.9530	0.9518	9.98
6	0.01	16	50	Adamax	Inception-v3	0.9262	0.9242	0.9262	0.9212	8.85
7	0.1	32	30	RMSprop	Inception-v3	0.8322	0.6926	0.8322	0.7560	5.33
8	0.1	64	20	Adamax	Inception-ResNet-v2	0.9530	0.9539	0.9530	0.9534	5.13

Hasil eksperimen menunjukkan bahwa arsitektur Inception-v3 mencapai performa terbaiknya ketika dikonfigurasi dengan *learning rate* 0.001, *batch size* 64, *epoch* 40, dan *optimizer* Adam, dengan akurasi sebesar 93.29%, presisi 93.79%, *recall* 93.29%, dan *F1-score* sebesar 92.58%, namun membutuhkan waktu pelatihan yang lama yaitu 7.06 menit. Sedangkan Inception-ResNet-v2 memberikan performa tertinggi pada kombinasi *learning rate* 0.1, *batch size* 64, *epoch* 20, dan *optimizer*

Adamax, menghasilkan akurasi 95.30%, presisi 95.39%, *recall* 95.30%, dan *F1-score* tertinggi 95.34% dengan waktu pelatihan tercepat yaitu 5.13 menit. Yang menarik dari hasil ini adalah bagaimana perubahan *hyperparameter* dapat memberikan dampak signifikan terhadap performa model, khususnya pada *learning rate* yang lebih tinggi.

3.2. Evaluasi Model Terbaik

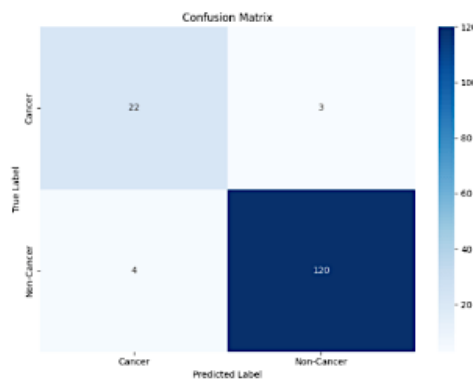
Tabel 2 merangkum hasil evaluasi dari konfigurasi terbaik masing-masing arsitektur CNN berdasarkan kombinasi *hyperparameter* yang telah diuji.

Tabel 2. Hasil Evaluasi Model CNN Terbaik

Learning Rate	Batch Size	Epoch	Optimizer	CNN Arsitektur	akurasi	Presisi	Recall	F1 Score	CPU TIME (minutes)
0.001	64	40	Adam	Inception-v3	0.9329	0.9379	0.9329	0.9258	7.06
0.1	64	20	Adamax	Inception-ResNet-v2	0.9530	0.9539	0.9530	0.9534	5.13

3.3. Confusion Matrix

Performa model Inception-ResNet-v2 dievaluasi menggunakan *confusion matrix* yang ditampilkan pada Gambar 4. *Confusion matrix* menggambarkan secara rinci hasil prediksi yang benar maupun salah terhadap dua kelas, yaitu kanker dan non-kanker.



Gambar 4. Hasil Confusion Matrix pada model *Inception-ResNet-v2*


Berdasarkan *confusion matrix*, diperoleh hasil sebagai berikut:

- *True Positive* (TP): 22 citra kanker berhasil diklasifikasikan dengan benar sebagai kanker.
- *True Negative* (TN): 120 citra non-kanker berhasil diklasifikasikan secara benar sebagai non-kanker.
- *False Positive* (FP): Terdapat 4 citra non-kanker yang salah diklasifikasikan sebagai kanker.
- *False Negative* (FN): Terdapat 3 citra kanker yang salah diklasifikasikan sebagai non-kanker

Secara umum, model model Inception-ResNet-v2 menunjukkan kinerja yang unggul dengan jumlah prediksi benar yang jauh lebih tinggi dibandingkan prediksi salah. Tingginya nilai TP dan TN menunjukkan bahwa model ini sangat efektif dalam membedakan antara citra kanker dan non-kanker. Sementara itu, nilai FP dan FN yang rendah mengindikasikan tingkat kesalahan klasifikasi yang minimal, yang sangat penting untuk aplikasi deteksi dini kanker payudara. Dari hasil ini, dapat disimpulkan bahwa model Inception-ResNet-v2 memiliki potensi yang tinggi untuk digunakan sebagai alat bantu diagnosis otomatis pada citra mammogram, karena mampu meminimalkan risiko kesalahan diagnosis baik untuk kasus positif maupun negatif.

3.4. Visualisasi Hasil

Evaluasi model tidak hanya terbatas pada metrik numerik seperti akurasi dan *confusion matrix*, tetapi juga perlu diperkuat melalui validasi visual. Pendekatan ini memungkinkan peneliti untuk mengamati secara langsung performa model dalam mengklasifikasikan citra. Gambar 5 memperlihatkan contoh kumpulan citra mammogram hasil klasifikasi dari model terbaik yaitu Inception-ResNet-v2. Setiap citra disertai label asli dan hasil prediksi model, dengan penanda visual berupa warna hijau untuk prediksi yang benar, dan warna merah jika terdapat kesalahan klasifikasi.



Gambar 5. Visualisasi Hasil Klasifikasi

4. KESIMPULAN

Melalui serangkaian eksperimen yang telah dilakukan, diperoleh kesimpulan bahwa arsitektur Inception-ResNet-v2 memberikan hasil yang lebih menjanjikan untuk klasifikasi mammogram dibandingkan Inception-v3 dengan tingkat akurasi mencapai 95.30%, presisi 95.39%, *recall* 95.30%, *F1-score* 95.34% dengan waktu pelatihan 5.13 menit. Keunggulan ini dipengaruhi oleh kombinasi arsitektur modular inception dan koneksi *residual* yang mampu mengekstraksi fitur kompleks pada citra medis dengan efisien. Selain itu, konfigurasi *hyperparameter* terbaik (*learning rate* 0.1, *batch size* 64, *epoch* 20, dan *optimizer* Adamax) juga berperan penting dalam menghasilkan konvergensi pelatihan yang optimal. Hasil evaluasi menggunakan *confusion matrix* memperkuat temuan kuantitatif, dengan jumlah prediksi benar yang tinggi dan kesalahan klasifikasi yang rendah. Visualisasi hasil klasifikasi lebih lanjut menunjukkan konsistensi model dalam mengenali fitur visual utama pada citra mammogram. Penelitian selanjutnya dapat memanfaatkan dataset yang lebih besar disertai segmentasi bagian sel yang terkena kanker. Selain itu, pengujian lebih lanjut dapat dilakukan pada arsitektur lain seperti EfficientNet atau DenseNet.

UCAPAN TERIMA KASIH

Peneliti mengucapkan terima kasih kepada Universitas Esa Unggul atas dukungan yang diberikan dalam pelaksanaan penelitian ini. Ucapan terima kasih juga disampaikan kepada tim radiologi dari rumah sakit di Sulaimani, Irak, atas kontribusinya dalam penyediaan dan validasi dataset mammogram. Tidak lupa, penghargaan setinggi-tingginya ditujukan kepada teman-teman

dan keluarga yang senantiasa memberikan motivasi, dorongan, dan semangat selama proses penelitian berlangsung.

DAFTAR PUSTAKA

- [1] B. JULIA, H. SUMARTI, and H. H. KUSUMA, "Klasifikasi Tumor Payudara Berbasis Ciri Tekstur pada Citra Mammografi Menggunakan Metode Naive Bayes," *MIND (Multimedia Artificial Intelligent Networking Database) Journal*, vol. 7, no. 2, pp. 165–176, 2022.
- [2] N. C. I. Natun, M. A. Santhia, and Y. R. Kaesmetan, "Identifikasi Pengenalan Wajah Berdasarkan Jenis Kelamin Menggunakan Metode Convolutional Neural Network (CNN)," *Journal of Technology and Informatics (JoTI)*, vol. 6, no. 1, pp. 50–57, 2024.
- [3] R. Setiawan, M. A. Hendrawan, D. B. Nugroho, A. N. R. Hakim, and others, "Deteksi Kanker Payudara Hasil Citra Mammografi menggunakan Metode Convolutional Neural Network (CNN) Arsitektur ResNet-50," *Jurnal Inovasi Informatika dan Teknologi Unggul*, vol. 1, no. 01, pp. 25–32, 2024.
- [4] A. Supriyanto, W. A. Kusuma, and H. Rahmawan, "Klasifikasi Kanker Tumor Payudara Menggunakan Arsitektur Inception-V3 Dan Algoritma Machine Learning," *J. Al-AZHAR Indones. SERI SAINS DAN Teknol*, vol. 7, no. 3, p. 187, 2022.
- [5] T. L. Nikmah, R. M. Syafei, D. N. Anisa, E. Juanara, and Z. Mahrus, "Inception ResNet v2 for Early Detection of Breast Cancer in Ultrasound Images," *Journal of Information System Exploration and Research*, vol. 2, no. 2, 2024.
- [6] K. B. Aqdar *et al.*, "Mammogram Mastery: A Robust Dataset for Breast Cancer Detection and Medical Education," *Data Brief*, p. 110633, 2024.
- [7] N. P. Setiawati, N. Nurmalitasari, and V. Atina, "Analisis Sentimen Aplikasi Tiktok Tokopedia Seller Center dengan Pendekatan Machine Learning: SVM, CNN, Naive," *Smart Comp: Jurnalnya Orang Pintar Komputer*, vol. 14, no. 1, pp. 32–42, 2025.
- [8] J. Anggara, F. R. Ramadhan, A. F. Syofian, A. A. Panjaitan, and R. F. Fithra, "Pengembangan Sistem Prediksi Harga dan Rekomendasi Mobil Bekas Berbasis Machine Learning," *Journal of Technology and Informatics (JoTI)*, vol. 7, no. 1, pp. 11–23, 2025.
- [9] A. Prayoga, P. Sukmasetya, M. R. A. Yudianto, R. A. Hasani, and others, "Arsitektur Convolutional Neural Network untuk Model Klasifikasi Citra Batik Yogyakarta," *Journal of Applied Computer Science and Technology*, vol. 4, no. 2, pp. 82–89, 2023.
- [10] O. Iparraguirre-Villanueva, V. Guevara-Ponce, O. Roque Paredes, F. Sierra-Liñan, J. Zapata-Paulini, and M. Cabanillas-Carbonell, "Convolutional neural networks with transfer learning for pneumonia detection," 2022.
- [11] E. G. Winarto, R. Rahmayati, and A. Lawi, "Implementasi Arsitektur Inception Resnet-V2 untuk Klasifikasi Kualitas Biji Kakao," *Proceeding KONIK (Konferensi Nasional Ilmu Komputer)*, vol. 5, pp. 132–137, 2021.