

## Klasifikasi Citra *Ultrasound* Kanker Payudara Menggunakan *MobileNet*

### *Ultrasound Image Classification of Breast Cancer Using MobileNet*

Heru Arwoko \*<sup>1</sup>, Sofia Ariyani<sup>2</sup>

<sup>1</sup>Teknik Informatika, Fakultas Teknik, Universitas Surabaya

<sup>2</sup>Teknik Elektro, Fakultas Teknik, Universitas Muhammadiyah Jember

Email: <sup>1</sup>heru\_a@staff.ubaya.ac.id, <sup>2</sup>sofia.ariyani@unmuhammadiyah.ac.id

\*Penulis Koresponden

Received: 31 Desember 2025

Accepted: 26 Januari 2026

Published: 02 Februari 2026



This work is licensed under  
a [Creative Commons Attribution 4.0](#)  
International License.  
Copyright (c) 2026 JUSTINDO

### ABSTRAK

Kanker payudara merupakan salah satu penyakit yang banyak dialami oleh wanita dan memiliki tingkat mortalitas yang tinggi apabila tidak terdeteksi pada tahap awal. Oleh karena itu, pengembangan sistem yang mampu melakukan diagnosis kanker payudara secara otomatis dan akurat menjadi sangat penting. Salah satu metode yang umum digunakan untuk deteksi dini kanker payudara adalah pemeriksaan citra medis ultrasonografi (USG), karena bersifat aman dan mudah diakses. Namun, citra USG memiliki sejumlah keterbatasan, seperti kualitas citra yang rendah, tingkat *noise* yang tinggi, serta karakteristik yang heterogen, sehingga menyulitkan proses klasifikasi jenis kanker. Dalam penelitian ini, diterapkan metode *transfer learning* untuk klasifikasi citra medis kanker payudara dengan memanfaatkan arsitektur *MobileNet* yang ringan dan efisien guna meningkatkan kinerja model. Proses klasifikasi dilakukan terhadap tiga kelas, yaitu tumor jinak, tumor ganas, dan jaringan normal. Dataset yang digunakan adalah BUSI (*Breast Ultrasound Images*) yang diperoleh dari *Baheya Hospital*, Kairo, Mesir, dengan total 780 citra USG payudara. Eksperimen dilakukan menggunakan beberapa arsitektur pra-latih, meliputi *MobileNet*, *MobileNetV2*, *Xception*, dan *InceptionV3*. Hasil evaluasi menunjukkan bahwa arsitektur *MobileNet* memberikan performa terbaik dengan nilai *F1-score* sebesar 89%. Temuan ini menunjukkan bahwa pendekatan yang diusulkan efektif dalam mengklasifikasikan citra USG, karena fitur diekstraksi secara otomatis dan bersifat global oleh jaringan saraf, tanpa memerlukan analisis fitur geometri secara manual.

**Kata kunci:** citra ultrasonografi, kanker payudara, CNN, transfer learning

### ABSTRACT

*Breast cancer is one of the most prevalent diseases affecting women and has a high mortality rate if not detected at an early stage. Therefore, the development of an automated and accurate system for breast cancer diagnosis is of critical importance. One of the most commonly used methods for early breast cancer detection is medical ultrasonography (US) imaging, as it is safe and easily accessible. However, ultrasound images suffer from several limitations, including low image quality, high noise levels, and heterogeneous characteristics, which make the classification of cancer types challenging. In this study, a transfer learning approach is employed for breast ultrasound image classification by utilizing the MobileNet architecture, which is lightweight and computationally efficient, to enhance model performance. The classification task is performed on three classes: benign tumors, malignant tumors, and normal tissue. The dataset used is the BUSI (Breast Ultrasound Images) dataset obtained from Baheya Hospital, Cairo, Egypt, consisting of 780 breast ultrasound images. Experiments are conducted using several pre-trained architectures, including MobileNet, MobileNetV2, Xception, and InceptionV3. The evaluation results demonstrate that the MobileNet architecture achieves the best performance with an F1-score of 89%. These results indicate that the proposed approach is effective for classifying ultrasound images, as features are automatically and globally learned by the neural network without requiring manual geometric feature analysis.*

**Keywords:** ultrasound imaging, breast cancer, CNN, transfer learning

## 1. Pendahuluan

Berdasarkan data dari World Health Organization (WHO), jumlah kematian akibat kanker payudara pada tahun 2020 diperkirakan mencapai 684.996 kasus (Aristokli et al., 2022). Ultrasonografi (USG) merupakan salah satu perangkat diagnostik medis yang banyak digunakan dalam praktik klinis untuk mendeteksi penyakit kanker. USG memiliki berbagai keunggulan, antara lain biaya yang relatif rendah, waktu akuisisi citra yang singkat, bersifat portabel, aman, akurat, serta tidak menghasilkan paparan radiasi berbahaya. Sejak awal perkembangan penelitian penyakit kanker, teknologi USG telah berperan penting dalam proses pengukuran, identifikasi, serta penentuan stadium perkembangan kanker. Namun demikian, ketepatan analisis citra USG secara manual sangat bergantung pada pengalaman dan ketelitian dokter atau operator, sehingga potensi terjadinya kesalahan identifikasi tetap ada. Banyak metode klasifikasi citra ultrasound payudara masih menghadapi tantangan besar dalam mendapatkan akurasi diagnosis yang tinggi akibat variabilitas bentuk dan tekstur tumor serta keterbatasan dataset yang kompleks serta bergantung pada interpretasi manual radiolog, sehingga perlu dikembangkan sistem klasifikasi otomatis berbasis deep-learning seperti yang dilakukan Rosadi et.al. (2025).

Pemanfaatan analisis citra USG berbasis komputer menjadi langkah krusial dalam mendukung proses diagnosis, klasifikasi, dan deteksi dini kanker. Deteksi dini kanker mampu menurunkan angka kematian secara signifikan, sebagaimana dilaporkan oleh Al-Dhabyani et al. (2019). Selain itu, Abdullah et al. (2021) menyatakan bahwa kanker payudara masih menjadi salah satu penyebab utama kematian pada wanita di seluruh dunia. Tantangan utama dalam pengolahan citra USG terletak pada kualitas citra yang rendah dan tingkat *noise* yang tinggi sehingga menyulitkan proses analisis dan klasifikasi.

Dalam konteks klasifikasi kanker payudara, Idawati et al. (2024) menyatakan bahwa proses klasifikasi bertujuan untuk menentukan jenis dan karakteristik kanker berdasarkan ciri sel-sel kanker. Pada penelitian tersebut digunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur VGG-16, yang menghasilkan performa terbaik dengan konfigurasi *optimizer SGD*, *learning rate* 0,001, *epoch* 20, dan *batch size* 32, dengan akurasi sebesar 78,87% serta nilai F1-score sebesar 74,67%. Pada penelitian tersebut untuk meningkatkan kecepatan pelatihan dan akurasi model, digunakan pendekatan *transfer learning* dengan memanfaatkan model CNN yang telah dilatih sebelumnya.

Pada penelitian Siden et.al. (2025) menyatakan bahwa *deep learning* dengan model arsitektur ResNet18 terbukti efektif dalam mengekstraksi fitur citra secara otomatis dan meningkatkan performa klasifikasi kanker payudara dari citra medis seperti *ultrasound*, dengan sejumlah studi penerapan menunjukkan akurasi tinggi pada pendekatan transfer learning dan model CNN *pretrained*.

Berbagai penelitian menunjukkan efektivitas *deep learning* dalam klasifikasi kanker payudara dari citra ultrasonografi (USG), khususnya melalui pendekatan *transfer learning* dengan arsitektur *Convolutional Neural Network* (CNN) *pretrained* seperti *ResNet*, *Inception*, dan *MobileNet*. AlZoubi et al. (2024) membandingkan performa transfer learning dengan desain arsitektur otomatis untuk mendeteksi lesi payudara dan menunjukkan bahwa pendekatan CNN yang diadaptasi secara otomatis mampu memberikan keunggulan performa pada beberapa skenario pengujian.

Pendekatan lain Uysal et. al. (2023) melaporkan bahwa model *pretrained* seperti *ResNet50* dan *Inception-V3* mampu mencapai performa yang kompetitif pada dataset yang diperluas, dengan tingkat akurasi yang mendekati 95% serta nilai metrik evaluasi lain yang memadai untuk mendukung diagnosis klinis.

Secara keseluruhan, kajian sistematis Dan et al. (2024) melaporkan bahwa integrasi *deep learning* dalam diagnosis kanker payudara berbasis USG memberikan performa diagnostik yang menjanjikan dan relatif konsisten di berbagai dataset serta kondisi klinis yang berbeda.

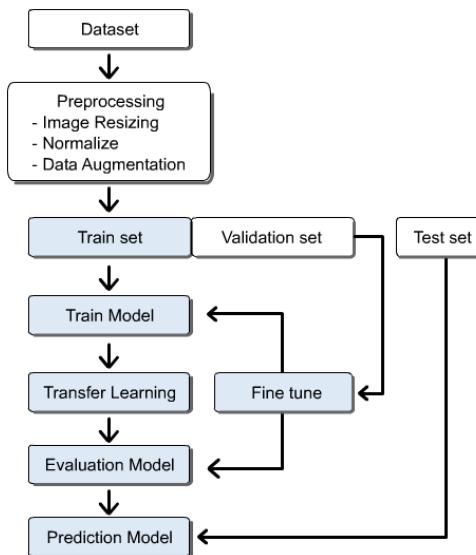
Berkaitan dengan upaya peningkatan kinerja model, penelitian ini bertujuan untuk meningkatkan akurasi klasifikasi kanker payudara dengan mengembangkan dan membandingkan performa beberapa arsitektur CNN berbasis *transfer learning*, yaitu *MobileNet*, *MobileNetV2*, *Xception*, dan *InceptionV3*. Citra ultrasonografi payudara diklasifikasikan ke dalam tiga kelas, yaitu jinak, ganas, dan normal, dengan menggunakan metrik evaluasi akurasi untuk menilai kinerja masing-masing

arsitektur. Hasil perbandingan tersebut digunakan untuk menentukan dan merekomendasikan arsitektur CNN yang paling optimal dan efisien dalam pengembangan sistem klasifikasi kanker payudara berbasis citra ultrasonografi.

## 2. Metode Penelitian

### 2.1. Dataset

Langkah awal dalam penelitian ini adalah pengumpulan dataset, *preprocessing*, ekstraksi fitur, pelatihan dan pengujian model, dan implementasi hasil model. Gambar 1 menunjukkan metode penelitian yang digunakan dalam penelitian ini.



Gambar 1. Diagram Penelitian

Dataset yang digunakan dalam penelitian ini berasal dari BUSI (*Breast Ultrasound Images*). Pada tahap praproses, seluruh citra diseragamkan ukurannya menjadi  $224 \times 224$  piksel menggunakan metode interpolasi *nearest neighbor*. Selanjutnya, dataset dibagi menjadi dua bagian, yaitu data pelatihan (*training set*) dan data validasi (*validation set*). Pada tahap awal pengembangan penelitian, ketersediaan dataset publik citra ultrasonografi payudara masih terbatas, sehingga menjadi salah satu tantangan utama dalam penelitian di bidang ini. Namun, Fahmi et al. (2020) telah mempublikasikan dataset BUSI yang hingga saat ini banyak digunakan sebagai acuan dalam berbagai penelitian terkait klasifikasi citra ultrasonografi payudara. Contoh visualisasi citra USG payudara ditunjukkan pada Gambar 2.

Class	Breast Ultrasound Image		
Benign Cancer (jinak)	benign (1).png	benign (3).png	benign (4).png
Malignant Cancer (ganas)	malignant (1).png	malignant (2).png	malignant (3).png
Normal	normal (1).png	normal (2).png	normal (3).png

Gambar 2. Visualisasi citra ultrasound

Dataset BUSI dikumpulkan dari *Baheya Hospital for Early Detection and Treatment of Women's Cancer* di Kairo, Mesir. Data tersebut diperoleh dari pasien wanita dengan rentang usia antara 25 hingga 75 tahun pada tahun 2018. Citra ultrasonografi pada dataset BUSI berupa citra *grayscale* dengan ukuran yang bervariasi, dengan resolusi rata-rata sekitar  $500 \times 500$  piksel. Dataset ini terdiri dari tiga kelas, yaitu tumor jinak, tumor ganas, dan jaringan normal. Selanjutnya, dataset dibagi dengan rasio 20% untuk data uji, sehingga diperoleh 157 citra sebagai data pengujian dan 623 citra sebagai data pelatihan, sebagaimana ditunjukkan pada Tabel 1. Citra *ultrasound* memperlihatkan karakteristik tekstur jaringan payudara dengan tingkat kontras yang rendah serta adanya *noise* yang menjadi ciri khas pencitraan ultrasonografi. Pada kelas normal, struktur jaringan terlihat relatif homogen tanpa indikasi massa abnormal, sedangkan pada kelas jinak dan ganas tampak area hitam dengan bentuk dan batas yang berbeda. Perbedaan karakteristik visual antar kelas inilah yang menjadi dasar dalam proses klasifikasi citra *ultrasound* menggunakan metode *Convolutional Neural Network* (CNN).

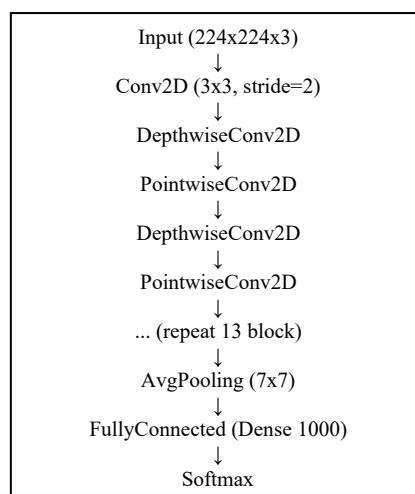
Tabel 1. Jumlah Data Citra per Kelas

Class	Number of Testing Images	Number of Training Images	Total Images
Benign Cancer	88	349	437
Malignant Cancer	42	168	210
Normal	27	106	133
Total	157	623	780

Berdasarkan hasil visualisasi, citra USG kanker jinak umumnya menunjukkan adanya area hitam berbentuk bulat dengan ukuran relatif kecil. Sebaliknya, pada citra USG kanker ganas tampak area hitam berukuran lebih besar. Sementara itu, pada citra USG payudara normal tidak ditemukan keberadaan area hitam tersebut.

## 2.2. Ekstraksi Fitur

Fitur pada setiap citra diekstraksi menggunakan CNN. *MobileNet* merupakan salah satu arsitektur CNN yang dirancang khusus untuk kebutuhan perangkat mobile dan sistem *embedded*. Arsitektur ini mengadopsi *depthwise separable convolution* guna menekan kompleksitas komputasi dan latensi model. *Depthwise separable convolution* terdiri atas dua tahap utama, yaitu *depthwise convolution*, yang menerapkan satu filter pada setiap saluran input secara terpisah, serta *pointwise convolution*, yang berfungsi mengombinasikan keluaran dari tahap sebelumnya melalui konvolusi  $1 \times 1$ . Pendekatan ini mengurangi jumlah parameter dan operasi komputasi secara signifikan dibandingkan konvolusi standar. Desain arsitektur *MobileNet* ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur MobileNet

Dengan struktur yang ringan dan efisien, *MobileNet* mampu mempertahankan performa akurasi yang kompetitif meskipun menggunakan sumber daya komputasi yang terbatas. Karakteristik tersebut menjadikan *MobileNet* sangat sesuai untuk penerapan transfer learning, khususnya pada dataset berukuran kecil hingga menengah, karena dapat mempercepat proses pelatihan serta meningkatkan kemampuan generalisasi model. Selain itu, fleksibilitas dalam mengatur trade-off antara kecepatan dan akurasi menjadikan *MobileNet* pilihan yang efektif untuk aplikasi real-time dan tugas klasifikasi citra medis. *MobileNet* merupakan arsitektur CNN berbasis perangkat mobile yang dikembangkan untuk mengatasi keterbatasan sumber daya komputasi tanpa mengorbankan kinerja model secara signifikan.

### 2.3. Model Training dan Testing

Sebelum proses pelatihan dan pengujian dilakukan, dataset dibagi ke dalam dua *subset*, yaitu data latih dan data uji. Data latih digunakan untuk melatih model, sedangkan data uji berfungsi untuk mengevaluasi kinerja model yang telah dilatih. Pembagian dataset dilakukan dengan proporsi 80% untuk data latih dan 20% untuk data uji. Pada penelitian ini digunakan beberapa model *pre-trained* berbasis *transfer learning*, yaitu *MobileNet*, *MobileNetV2*, *Xception*, dan *InceptionV3*. Seluruh model diimplementasikan dengan ukuran citra masukan sebesar 224×224 piksel dan terdiri dari tiga saluran warna. Penyesuaian *hyperparameter* dilakukan, salah satunya dengan mengatur parameter *include\_top* menjadi *false* agar lapisan klasifikasi akhir dapat disesuaikan dengan jumlah kelas pada tugas klasifikasi. Proses pelatihan model menggunakan algoritma optimasi Adam dengan laju pembelajaran sebesar 0,001 dan ukuran batch sebanyak 5. Fungsi *loss* yang digunakan adalah *categorical cross-entropy*, sedangkan metrik evaluasi yang diterapkan adalah *categorical accuracy*. Model dilatih selama 50 *epoch*, sebagaimana dirangkum pada Tabel 2.

Tabel 2. Hyperparameter

Hyperparameter	Value
Input Size	(224,224,3)
Include Top	<i>False</i>
Optimization	Adam
Learning Rate	0.001
Epoch	50
Batch Size	8
Dense Layer	<i>Dense(512, relu) → Dropout(0.3) → Dense(128, relu) → Dense(3, softmax)</i>
Output Classes	3 Classes (Benign, Malignant, Normal)

Pada tahap pengujian, setiap model dievaluasi menggunakan data uji dan menghasilkan matriks konfusi dengan tiga kelas, yaitu kelas 0 untuk kanker jinak, kelas 1 untuk kanker ganas, dan kelas 2 untuk jaringan normal. Selain analisis matriks konfusi, kinerja model juga dibandingkan berdasarkan metrik evaluasi lainnya, meliputi akurasi, presisi, *recall*, dan skor F1.

## 3. Hasil dan Pembahasan

Sebelum dilakukan proses pelatihan model, citra ultrasonografi payudara terlebih dahulu melalui tahap *preprocessing* untuk meningkatkan kualitas data. Tahapan preprocessing meliputi *resizing* citra ke ukuran input standar sesuai dengan kebutuhan masing-masing arsitektur CNN, normalisasi nilai piksel untuk mempercepat proses konvergensi model, serta pembagian dataset ke dalam data pelatihan dan data pengujian. Selain itu, dilakukan augmentasi data berupa rotasi, *flipping*, dan *zooming* guna meningkatkan variasi data serta mengurangi risiko *overfitting* akibat keterbatasan jumlah citra *ultrasound*. Tahap *preprocessing* data pada penelitian ini dilakukan menggunakan *ImageDataGenerator* untuk menyiapkan citra ultrasonografi sebelum masuk ke proses pelatihan model. Seluruh citra terlebih dahulu diubah ukurannya (*resizing*) sesuai dengan kebutuhan masing-masing arsitektur CNN, yaitu 224×224 piksel untuk *MobileNet* dan *MobileNetV2* serta 299×299 piksel untuk *Xception* dan *InceptionV3*, kemudian dilakukan normalisasi nilai piksel dengan skala 1/255 agar berada pada rentang [0,1]. Untuk meningkatkan variasi data dan

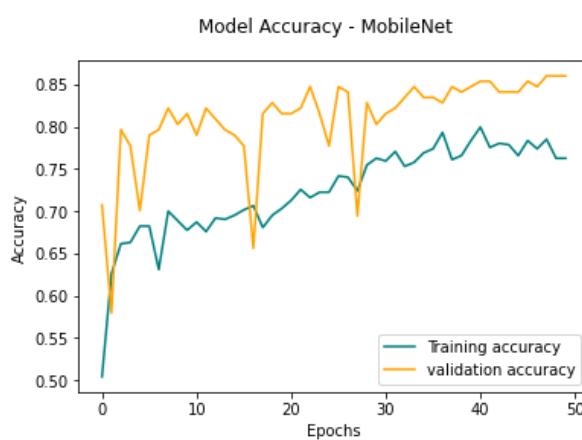
mengurangi risiko *overfitting*, diterapkan augmentasi data pada citra pelatihan berupa rotasi hingga 20 derajat, *horizontal flipping*, *zooming* sebesar 0,2, *shearing* 0,1, serta pergeseran lebar dan tinggi citra masing-masing hingga 20%, sementara citra validasi hanya dilakukan normalisasi tanpa augmentasi.

### 3.1. Proses Training

Setelah tahap *preprocessing*, dilakukan proses pelatihan model menggunakan pendekatan *transfer learning* dengan memanfaatkan model CNN pralatih (*pretrained*) berbobot *ImageNet*, yaitu *MobileNet*, *MobileNetV2*, *Xception*, dan *InceptionV3*, di mana lapisan dasar dibekukan (*freeze*) dan ditambahkan lapisan klasifikasi berupa *Global Average Pooling*, *fully connected layer*, serta *dropout* untuk meningkatkan kemampuan generalisasi model. Proses pelatihan dilakukan selama 50 *epoch* dengan *batch size* sebesar 8 menggunakan fungsi optimasi Adam dan fungsi *loss categorical cross-entropy*, serta didukung oleh penerapan *class weight* untuk menangani ketidakseimbangan data kelas. Selama pelatihan, performa model dipantau menggunakan data validasi dan hasil terbaik disimpan melalui mekanisme model *checkpoint*.

Tahap selanjutnya adalah evaluasi dan prediksi model, di mana model yang telah dilatih digunakan untuk melakukan prediksi terhadap data validasi dengan menghasilkan label kelas berdasarkan probabilitas tertinggi. Hasil prediksi kemudian dievaluasi menggunakan *confusion matrix* dan metrik klasifikasi seperti akurasi dan F1-score. Selain itu, waktu pelatihan dicatat untuk membandingkan efisiensi komputasi masing-masing arsitektur CNN, sehingga dapat ditentukan model yang paling optimal dan efisien dalam melakukan klasifikasi kanker payudara berbasis citra ultrasonografi.

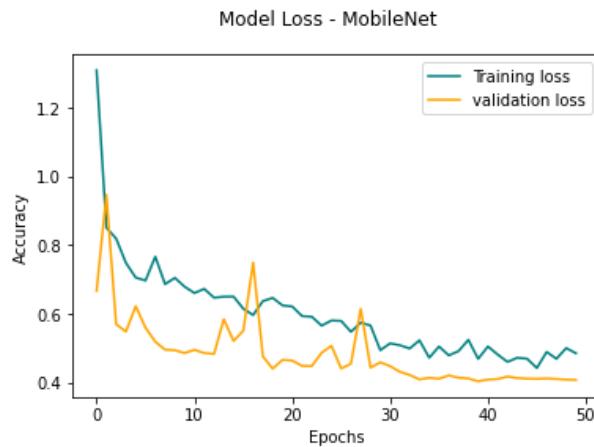
Proses pelatihan menggunakan arsitektur *MobileNet* dilakukan selama 50 *epoch*. Model mencapai nilai *loss* terendah pada *epoch* ke-50 dengan akurasi pelatihan sebesar 84%, serta waktu pelatihan rata-rata sekitar 42 detik pada setiap *epoch*. Pelatihan model *MobileNetV2* juga dilakukan selama 50 *epoch* dan menghasilkan *loss* terendah pada *epoch* ke-50 dengan akurasi pelatihan sebesar 78%. Rata-rata waktu pelatihan untuk setiap *epoch* pada arsitektur ini adalah 33 detik. Arsitektur *Xception* dilatih selama 50 *epoch* dan memperoleh nilai *loss* terendah pada *epoch* ke-50 dengan akurasi pelatihan sebesar 73%. Namun, model ini membutuhkan waktu komputasi yang lebih besar, dengan rata-rata durasi pelatihan mencapai 261 detik per *epoch*. Sementara itu, pelatihan model *InceptionV3* berlangsung selama 50 *epoch* dan mencapai *loss* terendah pada *epoch* ke-50 dengan akurasi pelatihan sebesar 76%. Waktu pelatihan rata-rata yang dibutuhkan oleh model ini adalah sekitar 98 detik per *epoch*. Grafik akurasi pelatihan untuk arsitektur *MobileNet* ditunjukkan pada Gambar 4.



Gambar 4. Grafik akurasi saat *training*

Gambar 5 menunjukkan grafik *training loss* dan *validation loss* dari model *MobileNet* selama proses pelatihan. Terlihat bahwa nilai *training loss* mengalami penurunan yang signifikan pada epoch awal dan kemudian menurun secara bertahap hingga akhir pelatihan. Hal ini menunjukkan bahwa model mampu mempelajari pola dan fitur penting dari data latih dengan baik. Sementara itu, *validation loss* juga menunjukkan tren penurunan yang relatif stabil, meskipun terdapat beberapa fluktuasi pada beberapa epoch. Fluktuasi tersebut mengindikasikan adanya variasi

dalam proses generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Namun demikian, tidak terlihat peningkatan *validation loss* yang tajam di akhir pelatihan, sehingga dapat disimpulkan bahwa model tidak mengalami *overfitting* secara signifikan. Secara keseluruhan, kesesuaian tren antara *training loss* dan *validation loss* menunjukkan bahwa arsitektur *MobileNet* memiliki kemampuan generalisasi yang baik dan proses pelatihan berlangsung secara stabil pada dataset citra USG yang digunakan.



Gambar 5. Grafik loss saat training

### 3.2. Analisa dan Pembahasan

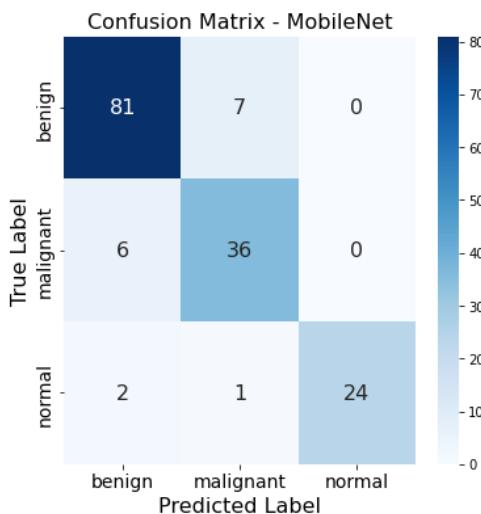
Setelah proses pelatihan selesai, hasil evaluasi dari seluruh model yang telah dilatih dibandingkan secara komprehensif. Selanjutnya, model-model tersebut digunakan untuk melakukan klasifikasi pada data uji yang berjumlah 157 citra. Berdasarkan hasil evaluasi, model *MobileNet* menunjukkan kinerja terbaik dibandingkan model lainnya, dengan nilai akurasi rata-rata sebesar 0,89, presisi sebesar 0,90, recall sebesar 0,89, serta skor F1 sebesar 0,89. Rangkuman hasil pengujian setiap model disajikan pada Tabel 3. Secara umum, arsitektur *MobileNet* dan *MobileNetV2* menunjukkan kinerja yang lebih unggul dibandingkan *Xception* dan *InceptionV3* dalam tugas klasifikasi citra ultrasonografi. Keunggulan tersebut terutama disebabkan oleh penggunaan *depthwise separable convolution* pada *MobileNet*, yang lebih efisien dalam mengekstraksi fitur spasial penting pada citra USG yang memiliki pola tekstur kompleks dan banyak *noise*. Pendekatan ini memungkinkan model untuk menangkap korelasi antar fitur secara lebih efektif, sehingga berkontribusi terhadap peningkatan akurasi klasifikasi.

Tabel 3. Hasil Akurasi

Model	Class	F1	Rec.	Prec	Acc.
<i>InceptionV3</i>	benign	0.83	0.88	0.79	
	malignant	0.69	0.62	0.79	0.80
	normal	0.81	0.81	0.81	
	average	0.79	0.80	0.80	
<i>MobileNetV2</i>	benign	0.86	0.86	0.85	
	malignant	0.72	0.74	0.70	0.82
	normal	0.86	0.81	0.92	
	average	0.82	0.82	0.82	
<i>MobileNet</i>	benign	0.91	0.97	0.86	
	malignant	0.83	0.76	0.91	<b>0.89</b>
	normal	0.92	0.85	1.00	
	average	0.89	0.89	0.90	
<i>Xception</i>	benign	0.78	0.75	0.81	
	malignant	0.73	0.88	0.62	0.75
	normal	0.65	0.52	0.88	
	average	0.74	0.75	0.77	

Sebaliknya, *Xception* dan *InceptionV3* mengadopsi struktur blok yang lebih dalam dan kompleks, yang pada kasus ini kurang optimal untuk karakteristik citra USG. Kompleksitas arsitektur tersebut

berpotensi menyebabkan kesulitan dalam memodelkan hubungan antar piksel yang bersifat nonlinier dan tidak teratur, sehingga performa klasifikasi menjadi kurang maksimal. Gambar 6 menampilkan matriks konfusi hasil pengujian model MobileNet terhadap 157 data uji pada dataset citra USG yang digunakan dalam penelitian ini.



Gambar 6. Confusion Matrix: MobileNet

Sementara itu, *MobileNetV2* menempati peringkat kedua dalam kinerja klasifikasi. Hal ini diduga disebabkan oleh struktur blok pada *MobileNetV2* yang lebih kompleks, sehingga kurang optimal dalam proses pembelajaran pada karakteristik dataset yang digunakan dalam penelitian ini dan berpotensi menghambat kinerja pelatihan model.

#### 4. Kesimpulan

Penelitian ini mengembangkan sistem klasifikasi citra ultrasonografi (USG) menggunakan metode *Convolutional Neural Network* (CNN) berbasis *transfer learning* dengan arsitektur *MobileNet*, *MobileNetV2*, *Xception*, dan *InceptionV3*. Dataset yang digunakan diklasifikasikan ke dalam tiga kelas, yaitu kanker jinak, kanker ganas, dan jaringan normal. Proses ekstraksi fitur dilakukan melalui operasi konvolusi yang mampu menangkap keterkaitan antar piksel pada citra USG. Hasil pengujian menunjukkan bahwa model *transfer learning* *MobileNet*, *MobileNetV2*, *Xception*, dan *InceptionV3* masing-masing menghasilkan skor F1 sebesar 89%, 82%, 79%, dan 74%. Di antara seluruh arsitektur yang diuji, *MobileNet* menunjukkan kinerja terbaik dengan rata-rata akurasi sebesar 89%, presisi sebesar 90%, *recall* sebesar 89%, serta skor F1 sebesar 89%. Berdasarkan hasil penelitian ini, disarankan untuk menambah jumlah dataset citra USG agar kemampuan generalisasi model dapat ditingkatkan dan performa klasifikasi menjadi lebih optimal. Selain itu, eksplorasi penggunaan arsitektur CNN terlatih lainnya maupun pengembangan strategi optimasi lanjutan juga perlu dilakukan untuk meningkatkan akurasi klasifikasi citra USG payudara di masa mendatang.

#### Daftar Pustaka

- Abdullah, S.H., Sagheer, A.M. & Veisi, H., 2021. *Breast cancer classification using machine learning techniques: A review*. *Turkish Journal of Computer and Mathematics Education*, 12(2), pp.100–113. Turkey: *Turkish Journal of Computer and Mathematics Education*. <https://turcomat.org/index.php/turkbilmat/article/view/10604>
- Al-Dhabayani, W. & Fahmy, A., 2019. *Deep learning approaches for data augmentation and classification of breast masses using ultrasound images*. *International Journal of Advanced Computer Science and Applications*, 10(5), pp.1–11. New York: The Science and Information (SAI) Organization. <https://thesai.org/Publications/ViewPaper?Volume=10&Issue=5&Code=IJACSA&SerialNo=79>.

- Al-Dhabyani, W., Gomaa, M., Khaled, H. & Fahmy, A., 2019. *Dataset of breast ultrasound images. Data in Brief*, 28, 104863. Amsterdam: Elsevier. <https://doi.org/10.1016/j.dib.2019.104863>
- Aristokli, N. et al., 2022. *Comparison of the diagnostic performance of Magnetic Resonance Imaging (MRI), ultrasound and mammography for detection of breast cancer based on tumor type, breast density and patient's history: A review. Radiography*, 28(3), pp. 848–856. Available at: <https://doi.org/https://doi.org/10.1016/j.radi.2022.01.006>
- AlZoubi, A., Lu, F., Zhu, Y., et al., 2024. *Classification of breast lesions in ultrasound images using deep convolutional neural networks: Transfer learning versus automatic architecture design. Medical & Biological Engineering & Computing*. Berlin: Springer. <https://pubmed.ncbi.nlm.nih.gov/37735296/>
- Dan, Q., Xu, Z., Burrows, H., et al., 2024. *Diagnostic performance of deep learning in ultrasound diagnosis of breast cancer: A systematic review. npj Precision Oncology*, 8, 21. London: Nature Publishing Group. <https://pubmed.ncbi.nlm.nih.gov/38280946/>
- Idawati, R., Rini, D.P., Primanita, A. & Saputra, T., 2024. Klasifikasi kanker payudara menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur VGG-16. *Jurnal Sistem Komputer dan Informatika (JSON)*, 5(3), pp.529–537. Medan: STMIK Triguna Dharma. <https://doi.org/10.30865/json.v5i3.7553>
- Rosadi, M.I., Fatichah, C. and Yuniarti, A., 2025. *Breast Cancer Ultrasound Images Classification Using Hybrid Pre-Trained CNN and SVM*, in 2025 17th International Conference on Knowledge and Smart Technology (KST), pp. 231–236. <https://doi.org/10.1109/KST65016.2025.11003377>
- Siden, H.S. and Wijayakusuma, I.G.N.L., 2025. *Implementation of Convolutional Neural Networks (CNN) for Breast Cancer Detection Using ResNet18 Architecture*, *Journal of Applied Informatics and Computing*, 9(4), pp. 1423–1430. <https://doi.org/10.30871/jaic.v9i4.9746>
- Uysal, F. & Köse, M.M., 2023. *Classification of breast cancer ultrasound images with deep learning-based models. Engineering Proceedings*, 31(1), 8. Basel: MDPI. <https://www.mdpi.com/2673-4591/31/1/8>