



Artikel Penelitian

Perbandingan Arsitektur CNN Berbasis *Transfer Learning* untuk Klasifikasi pada *BreastMNIST*

Sazila Azka Adzkia^{a*}, Toni Arifin^b

^a Program Studi Sistem Informasi, Fakultas Teknologi Informasi, Universitas Adhirajasa Reswara Sanjaya, Kota Bandung, 40282, Indonesia

^b Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Adhirajasa Reswara Sanjaya, Kota Bandung, 40282, Indonesia

INFORMASI ARTIKEL

Sejarah Artikel:

Diterima Redaksi: 14 Juli 2025

Revisi Akhir: 12 September 2025

Diterbitkan Online: 16 September 2025

KATA KUNCI

CNN,
Kanker Payudara,
Klasifikasi,
Transfer Learning,
Ultrasonografi

KORESPONDENSI

E-mail: 16213012@ars.ac.id*

A B S T R A C T

Kanker payudara adalah salah satu penyebab utama kematian di kalangan Wanita, terutama di negara berkembang seperti Indonesia. Deteksi dini sangat penting untuk meningkatkan tingkat kesembuhan dan menurunkan angka kematian. Penelitian ini bertujuan untuk meningkatkan kemampuannya dalam mengidentifikasi tumor kanker dengan memaksimalkan nilai recall serta membandingkan berbagai model Convolutional Neural Network (CNN) berbasis transfer learning guna menemukan model yang paling optimal. Arsitektur CNN yang dikaji dalam penelitian ini meliputi MobileNetV2, ResNet50, VGG16, dan AlexNet. Seluruh model diterapkan pada dataset BreastMNIST, yang terdiri dari citra ultrasonografi dengan dua kelas, yaitu jinak dan ganas. Transfer learning digunakan untuk mengatasi tantangan akibat keterbatasan ketersediaan data citra medis yang telah diberi label. Kinerja model dievaluasi secara menyeluruh menggunakan metrik akurasi, presisi, recall, F1-score dan Area Under Curve (AUC). Hasil penelitian menunjukkan bahwa MobileNetV2 memberikan performa yang unggul dengan akurasi sebesar 91,14%, recall 94%, presisi 93%, F1-score 94%, dan AUC sebesar 0,9607. Temuan ini mengindikasikan bahwa MobileNetV2 berbasis *transfer learning* sangat efektif dalam mendeteksi tumor ganas dan merupakan arsitektur paling optimal dalam studi ini.

1. PENDAHULUAN

Kanker payudara merupakan penyebab utama kematian pada wanita di seluruh dunia, terutama di negara berkembang seperti Indonesia, di mana sebagian besar kasus terdiagnosis pada stadium lanjut[1]. Penyakit ini berasal dari proliferasi sel-sel abnormal pada jaringan payudara dan dapat berkembang menjadi kondisi yang mematikan jika tidak ditangani secara tepat waktu [2]. Pada periode 2014 hingga 2018, terjadi peningkatan jumlah kasus sebesar 0,5% setiap tahunnya. Pada tahun 2020, jumlah kematian akibat kanker payudara secara global mencapai 685.000 jiwa, dengan dua pertiga di antaranya terjadi di negara-negara berkembang [3]. Negara maju memiliki tingkat kelangsungan hidup yang lebih tinggi akibat deteksi dan pengobatan yang lebih baik [4].

Kanker payudara merupakan tantangan kesehatan yang signifikan di negara berpendapatan menengah ke bawah, termasuk Indonesia, di mana akses terhadap diagnosis dini dan pengobatan masih terbatas [4]. Di Indonesia, rendahnya kesadaran akan deteksi dini menyebabkan sekitar 70% pasien datang dalam kondisi stadium lanjut, yang berdampak negatif terhadap pilihan pengobatan dan prognosis [5]. Peningkatan deteksi dini sangat penting untuk memperbaiki hasil klinis dan meminimalkan biaya pengobatan.

Tingginya angka kematian akibat kanker payudara sebagian besar disebabkan oleh kurangnya deteksi dini. Deteksi dini sangat penting karena memungkinkan penanganan yang lebih ringan dan biaya yang lebih efisien, sehingga meningkatkan peluang kesembuhan. Pemeriksaan ultrasonografi dan mamografi terbukti

lebih efektif dibandingkan dengan pemeriksaan payudara sendiri (SADARI). Secara khusus, ultrasonografi menunjukkan sensitivitas yang lebih tinggi, terutama pada perempuan Asia, serta memiliki keunggulan berupa keamanan karena tidak menggunakan radiasi, biaya yang lebih terjangkau, dan aksesibilitas yang lebih tinggi [6].

Interpretasi citra ultrasonografi sangat dipengaruhi oleh subjektivitas dan tingkat keahlian radiolog. Hal ini dapat menyebabkan variabilitas dalam hasil diagnosis antar individu [2]. Oleh karena itu, sistem yang memanfaatkan teknologi menjadi sangat penting untuk meningkatkan klasifikasi citra ultrasonografi, sehingga dapat memperbaiki akurasi dan konsistensi hasil diagnosis.

Kemajuan teknologi informasi, khususnya *deep learning*, telah memberikan dampak yang signifikan di sektor kesehatan, terutama dalam analisis citra medis untuk diagnosis kanker payudara [7]. *Deep learning* memiliki kemampuan untuk mengenali pola yang kompleks, meningkatkan akurasi diagnosis, mengurangi kesalahan, serta meringankan beban kerja tenaga medis [8]. *Deep learning*, yang merupakan bagian dari *machine learning*, menggunakan arsitektur berlapis untuk memodelkan pola data secara hierarkis, mulai dari fitur dasar hingga kompleks [9]. Kemampuannya dalam rekayasa fitur (*feature engineering*) dan penanganan data berskala besar menjadikannya lebih unggul dibandingkan metode *machine learning* tradisional [10].

Belakangan ini, algoritma *deep learning*, khususnya *Convolutional Neural Network* (CNN), telah menarik perhatian besar karena performanya yang unggul dalam tugas klasifikasi di berbagai bidang [11]. *Convolutional Neural Network* dirancang untuk menganalisis data yang berpola dan bertekstur [12], serta memiliki kemampuan untuk mengekstraksi fitur kompleks secara mandiri tanpa memerlukan rekayasa fitur secara manual [13].

Convolutional Neural Network (CNN) merupakan bidang khusus dalam *deep learning* yang secara dominan diterapkan dalam analisis data visual. CNN terdiri dari sejumlah lapisan terlatih, termasuk lapisan input, konvolusi, *pooling*, dan *fully connected*. Arsitektur CNN yang dikombinasikan dengan *transfer learning* telah menunjukkan efektivitas yang lebih tinggi dalam klasifikasi citra, melampaui model *machine learning* konvensional dalam beberapa tahun terakhir [14].

Kemajuan terbaru dalam *Convolutional Neural Network* (CNN) telah diarahkan untuk klasifikasi kanker payudara, dengan penggunaan model seperti AlexNet, VGG16, dan ResNet50 pada citra digital [15], serta MobileNetV2 pada citra ultrasonografi. Model-model ini umumnya terdiri dari lapisan konvolusi dan *pooling*, diikuti oleh lapisan *fully connected*, dengan *Softmax classifier* sebagai pengambil keputusan akhir [16].

Transfer Learning (TL) merupakan pendekatan *machine learning* yang memungkinkan penerapan pengetahuan dari model yang telah dilatih sebelumnya ke dalam tugas baru, sehingga meningkatkan performa pada dataset yang terbatas [17]. Pemanfaatan model pra-latih sebagai ekstraktor fitur tetap dapat meningkatkan akurasi, mempercepat proses pelatihan, dan mengurangi risiko *overfitting*, terutama dalam situasi dengan keterbatasan data medis [18], [19].

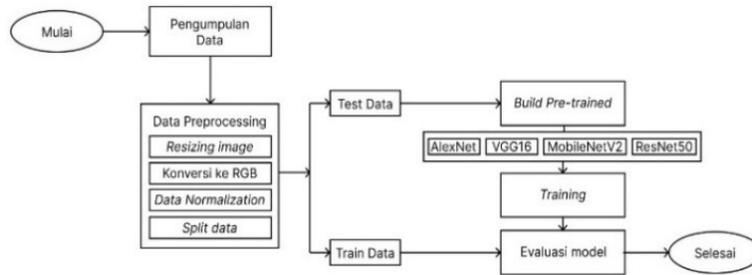
Transfer learning meningkatkan performa analisis citra medis melalui penerapan model *Convolutional Neural Network* (CNN) yang telah dilatih sebelumnya. *Convolutional Neural Network* telah terbukti mampu mengidentifikasi dan mengklasifikasikan berbagai kondisi medis dengan tingkat ketahanan yang tinggi. Integrasi antara *transfer learning* dan CNN menjadi elemen penting dalam kemajuan teknologi diagnosis pada pencitraan medis. Penelitian lebih lanjut di bidang ini diharapkan dapat secara signifikan meningkatkan akurasi diagnosis dan hasil klinis pasien [20].

Sebuah studi oleh Uysal dan Köse [21] membandingkan tiga model CNN berbasis *deep learning*, yaitu VGG16, ResNet50, dan ResNeXt50, untuk klasifikasi citra ultrasonografi kanker payudara ke dalam tiga kategori: normal, jinak, dan ganas. Penelitian ini menggunakan dataset yang terdiri dari 700 citra yang diperoleh dari Kaggle, yang telah melalui proses prapengolahan seperti *cropping*, normalisasi, dan teknik augmentasi seperti rotasi dan pergeseran RGB. Temuan menunjukkan bahwa ResNeXt50 mencapai akurasi tertinggi sebesar 85,83%, sementara ResNet50 menunjukkan stabilitas kinerja terbaik antar kelas dengan nilai AUC tertinggi sebesar 95,32%.

Studi oleh Matondo-Mvula dan Elleithy [22] mengevaluasi penerapan model konvolusional berbasis kuantum, khususnya *Quantum Convolutional Neural Network* (QCNN), menggunakan dataset dua kelas BreastMNIST. Hasil penelitian menunjukkan bahwa QCNN mencapai akurasi validasi sebesar 87,17%, melampaui CNN klasik yang memperoleh akurasi sebesar 83,33%. Namun, nilai *recall* untuk kategori ganas pada QCNN masih rendah, yaitu sebesar 57%, yang menunjukkan bahwa model ini masih cenderung melewatkan beberapa kasus kanker yang bersifat ganas.

Penelitian ini bertujuan untuk mengatasi keterbatasan yang ditemukan dalam dua penelitian sebelumnya. Studi oleh Uysal dan Köse [21] hanya berfokus pada klasifikasi tiga kelas tanpa mempertimbangkan metrik *recall* yang penting dalam mendeteksi kanker ganas. Ketidakseimbangan distribusi data, khususnya pada kelas normal, berdampak negatif terhadap kinerja model. Sementara itu, dalam studi Matondo-Mvula dan Elleithy [22] model QCNN menunjukkan potensi akurasi yang tinggi, namun penelitian tersebut masih terbatas pada simulasi kuantum dan belum memiliki penerapan di dunia nyata, serta menunjukkan nilai *recall* yang rendah pada kasus-kasus krusial. Selain itu, studi tersebut tidak mengeksplorasi perbandingan kinerja di antara arsitektur CNN klasik lainnya.

Berbeda dengan penelitian sebelumnya, studi ini bertujuan untuk meningkatkan nilai *recall* dalam klasifikasi tumor ganas dengan mengevaluasi performa empat arsitektur CNN berbasis *transfer learning*, yaitu AlexNet, VGG16, ResNet50, dan MobileNetV2. Analisis dilakukan menggunakan dataset ultrasonografi dua kelas yang seimbang serta mengintegrasikan metrik evaluasi yang lebih komprehensif. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem klasifikasi citra kanker payudara berbasis kecerdasan buatan, dengan meningkatkan akurasi dan sensitivitas dalam mendeteksi tumor ganas.



Gambar 1. Metode Penelitian

2. METODE

2.1. Pengumpulan Data

Penelitian ini menggunakan pendekatan kuantitatif dengan mengintegrasikan eksperimen komputasi dan kerangka kerja *deep learning*. Studi ini memanfaatkan *image dataset* BreastMNIST, yang merupakan bagian dari koleksi MedMNIST v2 yang dipublikasikan oleh Yang et al [23] dan diperoleh dari situs <https://medmnist.com/>. Dataset ini terdiri dari citra ultrasonografi payudara dalam format grayscale dengan resolusi awal 28x28 piksel, sebanyak 780 citra, yang diklasifikasikan ke dalam dua kelas, yaitu 0 untuk tumor jinak dan 1 untuk tumor ganas.

2.2. Data Preprocessing

2.2.1. Resizing Image

Resizing Image adalah untuk mempercepat proses pelatihan dan mendemonstrasikan kemampuan ekstraksi fitur hanya dengan menggunakan lapisan konvolusi kuantum [22]. Pada penelitian ini, gambar asli berukuran 28x28, namun karena menggunakan penerapan *transfer learning* menambahkan ukuran menjadi 224x224 piksel.

2.2.2. Konversi RGB

Konversi *RGB* adalah proses mengubah citra *grayscale* atau (hitam-putih, 1 channel) menjadi citra berformat RGB (*Red, Green, Blue, 3 Channel*) agar sesuai dengan format input yang dibutuhkan oleh model *CNN pretrained*. [24]. Saat melakukan konversi ke RGB tidak ada informasi tambahan selain proses ini dilakukan dengan mereplikasi kanal *grayscale* sebanyak tiga kali sehingga membentuk citra dengan kanal (RGB) yang bertujuan untuk menyesuaikan format dimensi input agar sesuai dengan persyaratan arsitektur jaringan konvolusional yang digunakan dalam pendekatan *transfer learning*.

2.2.3. Data Normalization

Prapemrosesan data seperti normalisasi membantu meningkatkan kinerja model dengan menyesuaikan nilai piksel citra ke dalam rentang standar sebelum proses pelatihan dimulai [20].

2.2.4. Split Data

Selanjutnya, dalam pemrosesan data, dataset gambar *BreastMNIST* diperoleh dan dibagi menjadi 3 bagian, yaitu 80%

training (624 Citra Ultrasonografi), 10% *Validation* (78 Citra Ultrasonografi), 10% *Testing* (78 Citra Ultrasonografi).

2.3. Teknik Deep Learning

Deep learning merupakan pendekatan pembelajaran mesin yang mampu mengenali pola kompleks dalam data besar melalui arsitektur jaringan saraf tiruan [25]. Salah satu metode paling populer dalam *deep learning* untuk klasifikasi citra, khususnya *CNN*.

2.3.1. Convolutional Neural Network

Convolutional Neural Network (CNN) adalah jenis jaringan saraf tiruan yang dirancang khusus untuk pemrosesan data berbentuk tekstur dan pola [12], terutama citra digital. CNN unggul dalam mengekstraksi informasi kompleks secara otomatis tanpa rekayasa fitur manual (*feature engineering*) [13].

Metode CNN terdiri dari beberapa lapisan utama:

1. Convolutional Layer untuk mengekstraksi fitur spasial menggunakan filter/kernel.
2. Pooling Layer bertujuan untuk reduksi dimensi.
3. Fully Connected Layer untuk memproses klasifikasi akhir
4. Dan Softmax untuk melakukan pengambilan keputusan berdasarkan probabilitas kelas [16].

Dalam domain diskrit [25], operasi konvolusi didefinisikan dalam persamaan(1):

$$(f * g)[n] = \sum_{m=-\infty}^{\infty} f[m] \cdot g[n - m] \quad (1)$$

$f[m]$: Nilai input pada indeks ke- m

$g[n - m]$: Nilai kernel pada indeks ke- $n - m$

$(f * g)[n]$: Hasil konvolusi pada posisi n

\sum : Penjumlahan seluruh hasil kali antara input dan kernel

m : Indeks pergeseran dalam proses konvolusi

Dalam konteks CNN [25], output dari posisi (i, j) dan kanal ke- k . Pada *feature map* dihitung dalam persamaan (2):

$$y_{i,j,k} = \sum_{l=1}^F \sum_{m=1}^F \sum_{n=1}^{C_{in}} w_{l,m,n,k} \cdot x_i + l - 1, j + m - 1, n + b_k \quad (2)$$

Dengan:

$y_{i,j,k}$: Output pada posisi (i, j) dan kanal k

w : bobot filter

x : input

b : bias

Ukuran *output feature map* juga dihitung dalam persamaan (3):

$$\text{Output size} = \frac{W-F+2P}{S} + 1 \quad (3)$$

W: Ukuran input

F: Ukuran filter

P: *Padding*

S: *Stride*

2.3.2. AlexNet

Arsitektur *AlexNet* merupakan salah satu jenis dari model Jaringan Syaraf Konvolusional. Dalam model *AlexNet* yang diusulkan, terdapat lima lapisan konvolusi, serta dua lapisan yang terhubung sepenuhnya (*fully connected*) [26]. *AlexNet* digunakan untuk mengekstraksi fitur dari citra medis, mengurangi dimensi fitur yang diekstraksi dan akhirnya melakukan klasifikasi berdasarkan kelas pada gambar citra ultrasonografi [27].

2.3.3. VGG16

Arsitektur VGG16 merupakan sebuah model *deep learning convolutional neural network* (DCNN) yang dikembangkan oleh Simonyan dan Zisserman dari Visual Geometry Group (VGG), University of Oxford. Model ini dirancang untuk mengenali 1000 kategori gambar sebagai bagian dari 22.000 subset kategori dalam dataset ImageNet yang berisi lebih 14 juta gambar. VGG16 memiliki struktur jaringan yang lebih dalam dengan menggunakan lapisan konvolusi kecil berukuran 3x3 secara berturut-turut, yang memungkinkan ekstraksi fitur visual secara lebih rinci dan efisien [28]. Melalui implementasi model VGG16, penulis menerapkan VGG16 dengan strategi transfer learning untuk klasifikasi citra ultrasonografi. Lapisan konvolusional dari VGG16 digunakan sebagai *feature extractor*, sedangkan lapisan *fully connected* asli digantikan oleh jaringan klasifikasi baru yang di rancang untuk memenuhi tujuan klasifikasi tumor menjadi *benign* atau *malignant* [17].

2.3.4. MobileNetV2

MobileNetV2 merupakan suatu arsitektur Jaringan Syaraf Konvolusional yang dirancang khusus untuk memenuhi kebutuhan perangkat dengan sumber daya terbatas, seperti ponsel pintar dan perangkat *Internet of Things* (IoT) [29]. *MobileNetV2*, sebagai pengembangan dari versi sebelumnya, memiliki struktur khas yang mencakup lapisan konvolusi, *bottleneck*, dan *pooling*, serta mengimplementasikan residual terbalik dan fungsi aktivasi *ReLU* [30].

2.3.5. ResNet50

ResNet50 adalah salah satu arsitektur Jaringan Syaraf Konvolusional yang memiliki signifikansi tinggi karena penerapan *residual connection*, sehingga memungkinkan pelatihan jaringan sangat dalam hingga 5 lapisan tanpa mengalami permasalahan *vanishing gradient*. Pendekatan ini meningkatkan kemampuan model dalam mengidentifikasi fitur-fitur kompleks serta menghasilkan tingkat akurasi yang tinggi dalam pelaksanaan tugas klasifikasi citra [31].

2.4. Transfer Learning

Dalam penelitian ini, peneliti menerapkan pendekatan *transfer learning*. Salah satu pendekatannya adalah menggunakan model

pra-latih sebagai ekstraktor fitur tetap (*frozen*), tanpa melakukan pelatihan ulang pada layer awal (*Alruwaili*). Pendekatan ini telah terbukti sebagai suatu metode yang efektif dalam memanfaatkan model *Convolutional Neural Network* (CNN) yang telah dilatih sebelumnya, guna meningkatkan kinerja dalam analisis citra medis [20].

2.5. Metrik Evaluasi

Setelah melakukan *modelling* dan *training*, terdapat tahapan akhir yang krusial, yaitu Evaluasi kinerja model. Dalam proses penelitian ini, evaluasi kinerja model merupakan tahap penting dalam membangun CNN. Proses ini dilakukan dengan membagi data ke dalam set pelatihan, validasi, dan pengujian, serta mengevaluasi performa model menggunakan metrik seperti *accuracy*, *precision*, *recall*, dan *F1-Score*. Selain itu visualisasi hasil menggunakan *confusion matrix* dan *ROC Curve* juga diperlukan untuk menganalisis lebih lanjut performa model [24].

2.5.1. Accuracy

Mengukur proporsi prediksi yang benar terhadap seluruh data [25], pada persamaan (4):

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+F} \quad (4)$$

2.5.2. Precision

Proporsi data positif yang benar dari semua yang diprediksi positif [25], melalui persamaan (5):

$$\text{Precision} = \frac{TP}{TP+FP} \quad (5)$$

2.5.3. Recall (Sensitivitas)

Kemampuan model mengenali data positif [25], di definisikan dalam persamaan (6):

$$\text{Recall} = \frac{TP}{TP+FN} \quad (6)$$

2.5.4. F1-Score

Rata-rata harmonis antara *Precision* dan *Recall* [25], berikut persamaan (7):

$$F1 - \text{Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (7)$$

2.5.5. Specificity

Mengukur kemampuan model dalam mengenali data negatif [25], di definisikan dalam persamaan (8):

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (8)$$

2.5.6. Negative Predictive Value (NPV)

Proporsi negatif yang benar dari seluruh prediksi negatif [25], dalam persamaan (9):

$$\text{NPV} = \frac{TN}{TN+FN} \quad (9)$$

2.5.7. False Positive Rate

Proporsi negatif yang salah diklasifikasikan sebagai positif dari seluruh data yang sebenarnya negatif [25], di definisikan dalam persamaan (10):

$$FPR = \frac{FP}{FP+} \quad (10)$$

2.5.8. ROC Curve & AUC

ROC (Receiver Operating Characteristic) Curve adalah grafik yang menunjukkan kinerja model klasifikasi biner dengan membandingkan True Positive Rate atau Recall dan False Positive Rate [32], di definisikan pada persamaan (6) dan (10).

3. HASIL

3.1. Hasil Berdasarkan Model

Dalam penelitian ini, peneliti menggunakan platform *medmnist.com* untuk melatih dataset *BreastMNIST* citra Ultrasonografi dan menggunakan Bahasa pemrograman python dengan bantuan framework PyTorch. Proses pelatihan dan evaluasi model dilakukan menggunakan arsitektur CNN berbasis *transfer learning* seperti *AlexNet*, *VGG16*, *ResNet50*, *MobileNetV2*. Seluruh citra ultrasonografi dari dataset *BreastMNIST* telah diubah ukurannya menjadi 224x224 piksel agar sesuai dengan format input dari masing-masing model. Parameter pelatihan dan hasil evaluasi model disajikan secara rinci pada Tabel 1 dengan hasil masing-masing model.

Tabel 1. Model *Hyperparameter* pada Penelitian *Pre-trained*

Model	Learning Rate	Batch Size	Optimizer	Loss Function	Epochs
3 Arsitektur		32		Binary cross entropy	10
<i>MobileNetV2</i>	0.001	16	Adam		

Berdasarkan hasil penelitian pada Tabel 1 yang menyajikan evaluasi kinerja empat arsitektur model *Convolutional Neural Network* (CNN) berbasis *transfer learning*, yaitu *AlexNet*, *VGG16*, *ResNet50*, dan *MobileNetV2*, dalam klasifikasi citra ultrasonografi pada dataset *BreastMNIST*. Evaluasi dilakukan terhadap *epoch* terbaik, akurasi pelatihan (*Train Accuracy*), akurasi pengujian (*Test Accuracy*), serta metrik evaluasi untuk masing-masing kelas (*Benign* dan *Malignant*), meliputi *Precision*, *Recall*, dan *F1-Score*.

Tabel 2. Hasil Perbandingan Berdasarkan *Classification Report*

Arsitektur	Accuracy	Precision	Recall	F1-Score
<i>AlexNet</i>	87.18%	90%	93%	92%
<i>VGG16</i>	87.18%	91%	91%	91%
<i>MobileNetV2</i>	91.14%	93%	94%	94%
<i>ResNet50</i>	87.18%	89%	92%	90%

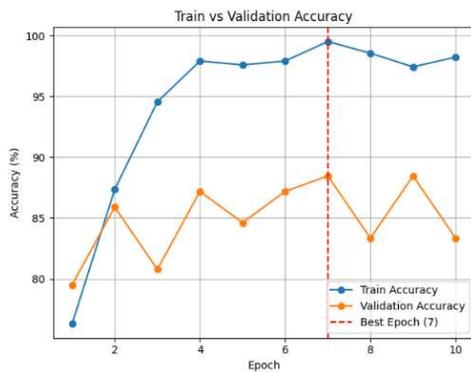
3.2. Hasil Berdasarkan Training dan Validation

Selama proses pelatihan, model pada gambar 2 menunjukkan peningkatan performa yang signifikan, terutama pada akurasi pelatihan yang meningkat stabil dari 74% hingga mencapai 98%. Hal ini mencerminkan kemampuan model *AlexNet* dalam mempelajari pola dari data pelatihan secara efektif. Namun demikian, akurasi validasi menunjukkan fluktuasi sepanjang proses pelatihan, dengan penurunan sementara pada titik tertentu yang mengindikasikan adanya potensi *overfitting*, di mana model terlalu menyesuaikan diri terhadap data pelatihan. Pada tahap akhir pelatihan, akurasi validasi mengalami peningkatan dan mencapai nilai tertingginya sebesar 88,5%, yang kemudian ditetapkan sebagai *best epoch*. Sementara itu, akurasi pelatihan pada tahap tersebut sedikit menurun menjadi 97,4%, namun masih berada dalam kategori tinggi dan stabil. Hasil ini menunjukkan bahwa model berhasil mencapai keseimbangan optimal antara pembelajaran dan generalisasi, sehingga mampu melakukan klasifikasi citra ultrasonografi dengan tingkat akurasi yang baik pada data yang belum pernah dilihat sebelumnya.



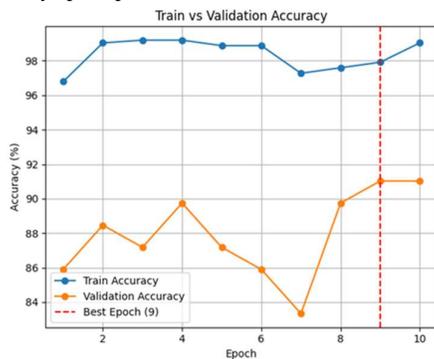
Gambar 2. *AlexNet*

Pola pelatihan model gambar 3 *VGG16* memperlihatkan kemajuan yang cukup pesat, terutama pada akurasi pelatihan yang meningkat dari sekitar 77% hingga mendekati 98%. Kenaikan ini mencerminkan efektivitas model dalam mengenali pola visual dari data pelatihan. Di sisi lain, akurasi validasi juga mengalami peningkatan, meskipun tidak sekuat pelatihan dan menunjukkan fluktuasi sepanjang proses. Titik performa terbaik dicapai ketika akurasi validasi menyentuh angka 88,5%, yang sekaligus menjadi indikator *best epoch*. Pada fase tersebut, akurasi pelatihan berada pada tingkat yang sangat tinggi ($\pm 98\%$), memperlihatkan bahwa model telah cukup matang dalam proses pembelajaran, sekaligus mampu mengklasifikasikan data validasi dengan presisi yang memadai. Namun, setelah melewati titik optimal tersebut, akurasi validasi cenderung menurun meskipun akurasi pelatihan tetap bertahan di angka tinggi. Kondisi ini menjadi indikasi bahwa model mulai mengalami *overfitting*, yakni terlalu fokus pada data pelatihan hingga kehilangan fleksibilitas dalam menghadapi data baru. Secara keseluruhan, performa *VGG16* cukup kuat, meskipun perlu perhatian terhadap stabilitas generalisasi di fase akhir pelatihan.



Gambar 3. VGG16

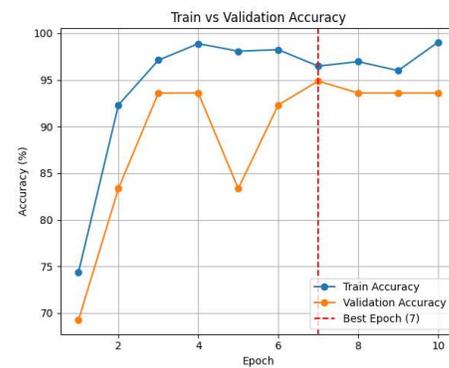
Performa pelatihan model *MobileNetV2* pada gambar 4 menunjukkan awal yang sangat menjanjikan, ditandai dengan peningkatan cepat pada akurasi pelatihan dari sekitar 97% menjadi hampir 99%. Akurasi validasi juga mengalami peningkatan bertahap dari 86% menuju 89%, meskipun sempat mengalami sedikit fluktuasi pada tahap awal. Memasuki pertengahan pelatihan, akurasi pelatihan tetap berada dalam kisaran tinggi, yakni sekitar 98%, namun justru terjadi penurunan pada akurasi validasi, yang mencapai titik terendah sekitar 85%. Penurunan ini menjadi indikasi adanya gejala *overfitting*, di mana model mulai kehilangan kemampuan generalisasi terhadap data yang belum pernah dilatih. Menjelang akhir pelatihan, performa validasi mengalami lonjakan signifikan hingga mencapai 91,03%, yang sekaligus menjadi *best epoch* dalam eksperimen ini. Akurasi pelatihan tetap tinggi dan stabil, memperlihatkan bahwa model berhasil menjaga konsistensi pembelajaran tanpa mengorbankan kemampuan generalisasi. Hasil ini menunjukkan bahwa *MobileNetV2* memiliki keunggulan dalam menyeimbangkan akurasi tinggi dengan kestabilan validasi, serta menjadi arsitektur dengan performa paling optimal dibandingkan model lainnya pada penelitian ini.



Gambar 4. MobileNetV2

Model *ResNet50* pada gambar 5 menunjukkan proses pembelajaran awal yang sangat efektif, ditandai dengan peningkatan akurasi pelatihan secara tajam dari 74% hingga mencapai 97% hanya dalam beberapa *epoch* pertama. Akurasi validasi pun meningkat signifikan hingga menyentuh angka 93,5%, mengindikasikan bahwa model mampu memahami pola data pelatihan dan menggeneralisasikannya dengan baik ke data validasi. Namun, seiring berlanjutnya pelatihan, terjadi penurunan drastis pada akurasi validasi hingga mencapai 83%, sementara akurasi pelatihan tetap tinggi. Kondisi ini mencerminkan potensi *overfitting*, yaitu ketika model mulai

terlalu menyesuaikan diri dengan data pelatihan dan kehilangan fleksibilitas terhadap data baru. Menariknya, pada fase akhir pelatihan, performa validasi kembali membaik. Puncaknya terjadi pada *epoch* ke-7, ketika akurasi validasi mencapai 94,87% dan akurasi pelatihan berada di angka 96,47%. Titik ini ditetapkan sebagai *best epoch*, karena menunjukkan keseimbangan terbaik antara pembelajaran dan kemampuan generalisasi. Setelah pencapaian tersebut, akurasi validasi cenderung stagnan tanpa peningkatan berarti, sementara akurasi pelatihan tetap berada pada tingkat tinggi. Hal ini menunjukkan bahwa pelatihan tambahan setelah *best epoch* tidak memberikan dampak signifikan terhadap performa validasi, sehingga *epoch* ke-7 menjadi representasi performa optimal dari *ResNet50* dalam eksperimen ini.

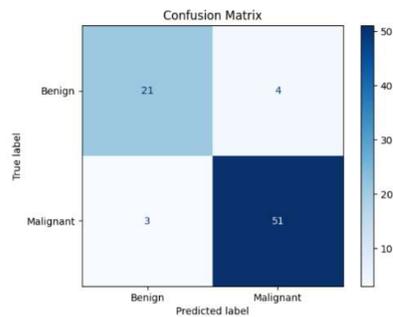


Gambar 5. ResNet50

3.3. Hasil Berdasarkan Testing

3.3.1. Confusion Matrix

Berdasarkan hasil evaluasi pada Gambar 6 yang menampilkan *confusion matrix* dari model *MobileNetV2* terhadap dataset *BreastMNIST*, diketahui bahwa model berhasil mengklasifikasikan 51 citra tumor ganas (*malignant*) dan 21 citra tumor jinak (*benign*) secara tepat. Meskipun demikian, terdapat sejumlah kesalahan klasifikasi, yaitu 4 citra *benign* yang salah diprediksi sebagai *malignant* (*false positive*) dan 3 citra *malignant* yang salah diprediksi sebagai *benign* (*false negative*). Dari distribusi klasifikasi tersebut, diperoleh akurasi sebesar 92,31%, dengan nilai presisi dan *recall* untuk kelas *malignant* masing-masing sebesar 92,73% dan 94,44%. Hasil ini menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan antara dua kategori utama tumor payudara, dengan tingkat kesalahan yang relatif rendah. Tingginya nilai *recall* menunjukkan bahwa model mampu mengenali sebagian besar kasus tumor ganas dengan baik, sedangkan presisi yang tinggi mengindikasikan rendahnya jumlah prediksi positif yang salah. Dengan demikian, model *MobileNetV2* dinilai memiliki potensi kuat untuk digunakan dalam sistem deteksi dini kanker payudara berbasis citra ultrasonografi, terutama karena kemampuannya dalam menjaga keseimbangan antara akurasi dan sensitivitas terhadap kelas mayoritas.



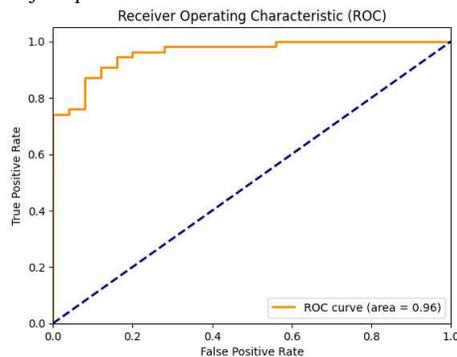
Gambar 6. Confusion Matrix pada MobileNetV2

Tabel 3. Perbandingan Berdasarkan Hasil Performa Model

Model	Train Accuracy	Test Accuracy	Val Accuracy	Test Loss
AlexNet	97.44%	87.18%	88.46%	0.425085
VGG16	99.52%	87.18%	88.46%	0.721224
ResNet50	96.47%	87.18%	94.87%	0.478258
MobileNetV2	97.92%	91.14%	91.03%	0.418502

3.3.2. Receiver Operating Characteristic (ROC)

Pada gambar 7, kurva ROC yang ditampilkan, model *MobileNetV2* menunjukkan kinerja klasifikasi yang sangat baik dalam mendeteksi klasifikasi citra pada dataset *BreastMNIST*. *Area Under the Curve (AUC)* yang diperoleh sebesar 0.9607 mengindikasikan bahwa model memiliki tingkat akurasi yang tinggi dalam membedakan kelas positif dan negatif. Nilai *AUC* yang mendekati 1 menunjukkan kemampuan prediktif yang kuat, di mana model mampu mencapai tingkat *True Positive Rate (TPR)* yang tinggi dengan tingkat *False Positive Rate (FPR)* yang relatif rendah. Hal ini menguatkan bahwa *MobileNetV2* efektif dalam mengklasifikasikan citra ultrasound payudara, sesuai dengan tujuan penelitian ini.



Gambar 7. ROC MobileNetV2

3.4. Hasil perbandingan model

Perbandingan hasil evaluasi model pada tabel 3 menunjukkan performa dari empat arsitektur CNN yang berbeda, yaitu *AlexNet*, *VGG16*, *ResNet50*, dan *MobileNetV2*. Berdasarkan data pada tabel IV.3, *MobileNetV2* menunjukkan akurasi pelatihan tertinggi sebesar 97.92% dan akurasi uji terbaik sebesar 91.14%, dengan akurasi validasi mencapai 91.03% dan *loss* terendah sebesar 0.418502. Sementara itu, *VGG16* mencatatkan akurasi pelatihan sebesar 99.52%, namun akurasi uji dan validasi keduanya berada pada angka yang sama, yaitu 87.18% dan 88.46% dengan *loss*

yang lebih tinggi dibandingkan model lainnya, yaitu 0.721224. *AlexNet* juga menunjukkan hasil pelatihan yang tinggi (97.44%) dengan akurasi uji 87.18% dan validasi 88.46%, serta *loss* 0.425085. *ResNet50* memiliki akurasi pelatihan 96.47% dengan hasil uji dan validasi yang sedikit lebih baik daripada *AlexNet*, yakni 87.18% dan 94.87% secara berturut-turut, dengan *loss* 0.478258. Secara keseluruhan, *MobileNetV2* tampil lebih unggul dalam hal akurasi uji dan validasi, sementara *VGG16* menunjukkan akurasi pelatihan yang lebih tinggi, namun diikuti dengan performa uji yang lebih rendah.

4. PEMBAHASAN

Hasil penelitian ini menunjukkan bahwa *MobileNetV2* memiliki performa paling optimal dengan akurasi 91,14%, *recall* 94%, presisi 93%, *F1-Score* 945, dan *AUC* 0,9607. Temuan ini memperkuat peran transfer learning dalam meningkatkan performa klasifikasi citra medis, khususnya pada dataset dengan jumlah terbatas seperti *BreastMNIST*.

Jika dibandingkan dengan penelitian sebelumnya oleh Uysal dan Köse [21], model *ResNeXt50* mampu mencapai akurasi tertinggi sebesar 85,83% dengan *AUC* 95,32%. Namun, penelitian tersebut tidak menyoroti metrik *recall* yang sangat penting dalam mendeteksi kasus tumor ganas. Penelitian ini justru berhasil menunjukkan bahwa *MobileNetV2* mampu mencapai *recall* tinggi (94%), sehingga lebih sensitif dalam mendeteksi tumor ganas dan berpotensi mengurangi kasus *false negative* yang berisiko dalam praktik klinis.

Sementara itu, penelitian oleh Matondo-Mvula dan Elleithy [22] yang menggunakan *Quantvolutional Neural Network (QCNN)* memperoleh akurasi validasi 87,17%. Akan tetapi, *recall* untuk kelas *malignant* masih rendah (57%), yang berarti banyak kasus kanker ganas tidak terdeteksi. Hasil penelitian ini menegaskan keunggulan *MobileNetV2* yang tidak hanya mencapai akurasi tinggi, tetapi juga mampu menjaga sensitivitas yang penting untuk deteksi dini kanker payudara.

Selain itu, studi oleh Alzoubi dkk. [17] dan Arooj dkk. [15] juga menekankan bahwa *transfer learning* mampu meningkatkan performa klasifikasi citra medis. Hasil penelitian ini konsisten dengan temuan mereka, namun memberikan tambahan kontribusi dengan menekankan aspek *recall* sebagai metrik evaluasi utama. Hal ini menjadi penting karena tujuan utama sistem pendukung diagnosis medis adalah meminimalkan kasus positif yang terlewatkan.

Penelitian ini secara khusus menggunakan *BreastMNIST*, yaitu dataset medis berukuran kecil yang berbasis format citra menyerupai *MNIST*. Karakteristik dataset ini menjadikan proses pelatihan dari awal (*training from scratch*) kurang optimal akibat keterbatasan jumlah data saat menggunakan model *deep learning*. Oleh karena itu, penerapan *transfer learning* menjadi sangat relevan untuk meningkatkan kemampuan generalisasi model.

Tabel 4. Perbandingan Berdasarkan Penelitian Terdahulu

Penelitian	Model Yang diuji	Transfer Learning	Dataset	Recall (%)
Uysal & Köse (2022)	VGG16, ResNet50, ResNeXt50	Tidak	780 Citra USG (<i>benign, malignant, normal</i>)	-
Matondo-Mvula & Elleithy	QCNN & CNN Klasik	Tidak	Breast Ultrasound Dataset (BUSI), 780 citra	57
Arooj dkk. (2022)	Customized AlexNet berbasis TL	Ya	USG & Histopathology (>10.000 Citra USG)	-
AlZoubi dkk. (2024)	CNN pretrained (VGG16, ResNet50, ResNeXt50) vs AutoML	Ya	780 Citra USG (<i>benign, malignant, normal</i>)	-
Penelitian ini (2025)	AlexNet, VGG16, ResNet50, MobileNet50	Ya	BreastMNIST (780 citra, <i>benign</i> dan <i>malignant</i>)	94

Secara keseluruhan, penelitian ini menegaskan bahwa *MobileNetV2* berbasis *transfer learning* lebih efektif dibandingkan arsitektur *CNN* lainnya pada dataset *BreastMNIST* yang berukuran kecil. Model ini mampu mencapai akurasi 91,14% sekaligus menjaga nilai *recall* tinggi sebesar 94% pada kelas *malignant*. Kontribusi utama penelitian ini terletak pada pembuktian efektivitas *transfer learning* untuk dataset medis terbatas, serta penekanan pada *recall* sebagai metrik evaluasi yang krusial dalam mendukung deteksi dini kanker payudara.

5. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilaksanakan, tujuan pertama penelitian, yaitu untuk meningkatkan performa model dalam mendeteksi tumor payudara ganas (*malignant*) pada dataset *BreastMNIST* berbasis citra ultrasonografi, khususnya dalam meningkatkan nilai *recall* pada kelas kanker ganas, telah tercapai dengan baik. Hasil evaluasi menunjukkan bahwa model *MobileNetV2* memberikan kinerja paling optimal dibandingkan arsitektur lainnya. Model ini berhasil memperoleh nilai *recall* sebesar 94% pada kelas *malignant*, yang menunjukkan tingkat sensitivitas yang tinggi dalam mendeteksi kasus kanker ganas. Pencapaian ini mencerminkan kemampuan model dalam mengurangi kesalahan klasifikasi terhadap kasus positif, sehingga sangat mendukung upaya deteksi dini kanker payudara secara lebih akurat dan andal.

Selanjutnya, sejalan dengan tujuan kedua penelitian, yakni untuk membandingkan hasil model arsitektur *CNN* yang memiliki kinerja terbaik berdasarkan metrik evaluasi, yaitu akurasi, *precision*, *recall*, *confusion matrix*, dan *ROC (AUC)*, diperoleh hasil bahwa *MobileNetV2* merupakan arsitektur dengan performa paling unggul secara menyeluruh. Model ini mencapai akurasi pengujian sebesar 91,14%, *precision* sebesar 93%, *F1-score* sebesar 94%, dan nilai *AUC* sebesar 0,9607, yang mengindikasikan kemampuan klasifikasi yang sangat baik dalam membedakan antara kelas *benign* dan *malignant*. Sementara itu, arsitektur lain seperti *AlexNet*, *VGG16*, dan *ResNet50* menunjukkan performa yang relatif lebih rendah serta kecenderungan *overfitting*. Dengan demikian, berdasarkan evaluasi menyeluruh terhadap seluruh metrik yang digunakan, dapat disimpulkan bahwa *MobileNetV2* merupakan arsitektur *CNN* paling efektif dan direkomendasikan dalam klasifikasi citra ultrasonografi untuk deteksi kanker payudara

Kontribusi utama dari penelitian ini adalah pembuktian efektivitas *transfer learning* pada dataset medis berukuran kecil seperti *BreastMNIST*, serta penegasan pentingnya penggunaan *recall* sebagai metrik evaluasi utama dalam klasifikasi kanker payudara. Hal ini memberikan dasar ilmiah bagi pengembangan sistem klasifikasi citra medis yang lebih andal, dengan tujuan mendukung deteksi dini kanker payudara sehingga dapat meningkatkan kualitas diagnosis dan pengambilan keputusan klinis.

DAFTAR PUSTAKA

- [1] A. V. Icanervilia *et al.*, "Early Detection of Breast Cancer in Indonesia: Barriers Identified in a Qualitative Study," *Asian Pacific J. Cancer Prev.*, vol. 24, no. 8, pp. 2749–2755, 2023, doi: [10.31557/APJCP.2023.24.8.2749](https://doi.org/10.31557/APJCP.2023.24.8.2749).
- [2] R. Resmiati and T. Arifin, "Klasifikasi Pasien Kanker Payudara Menggunakan Metode Support Vector Machine dengan Backward Elimination," *Sistemasi*, vol. 10, no. 2, p. 381, 2021, doi: [10.32520/stmsi.v10i2.1238](https://doi.org/10.32520/stmsi.v10i2.1238).
- [3] T. Arifin, I. W. P. Agung, E. Junianto, R. Rachman, I. R. Wibowo, and D. D. Agustin, "Breast cancer identification using machine learning and hyperparameter optimization," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 36, no. 3, pp. 1620–1630, 2024, doi: [10.11591/ijeecs.v36.i3.pp1620-1630](https://doi.org/10.11591/ijeecs.v36.i3.pp1620-1630).
- [4] L. Wilkinson and T. Gathani, "Understanding Breast Cancer as A Global Health Concern," *Br. J. Radiol.*, vol. 95, no. 1130, pp. 7–9, 2022, doi: [10.1259/BJR.20211033](https://doi.org/10.1259/BJR.20211033).
- [5] T. K. Dewi, R. A. C. Ruitter, R. Ardi, and K. Massar, "The role of psychosocial variables in breast self-examination practice: Result from focus group discussions in Surabaya, Indonesia," 2022.
- [6] L. Choridah, A. V. Icanervilia, A. A. Rengganis, J. At Thobari, M. J. Postma, and A. D.I. van Asselt, "Comparing the performance of three modalities of breast cancer screening within a combined programme targeting at-risk women in Indonesia: An implementation study," *Glob. Public Health*, vol. 18, no. 1, 2023, doi: [10.1080/17441692.2023.2284370](https://doi.org/10.1080/17441692.2023.2284370).
- [7] S. F. Ahmed *et al.*, *Deep learning modelling techniques: current progress, applications, advantages, and challenges*, vol. 56, no. 11. Springer Netherlands, 2023. doi: [10.1007/s10462-023-10466-8](https://doi.org/10.1007/s10462-023-10466-8).

- [8] S. Balasubramaniam, Y. Velmurugan, D. Jaganathan, and S. Dhanasekaran, "A Modified LeNet CNN for Breast Cancer Diagnosis in Ultrasound Images," *Diagnostics*, vol. 13, no. 17, pp. 1–28, 2023, doi: [10.3390/diagnostics13172746](https://doi.org/10.3390/diagnostics13172746).
- [9] I. D. Mienye and T. G. Swart, "A Comprehensive Review of Deep Learning Methods and Applications," *Deep Learn. Vis. Underst.*, pp. 7–58, 2024, [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0925231215017634>
- [10] G. Chhabra, S. Kumar, D. S. Raha, and D. G. C. Saha, "Analysis of Deep Learning in Real-World Applications: Challenges and Progress," *Tuijin Jishu/Journal Propuls. Technol.*, vol. 44, no. 2, pp. 281–289, 2023, doi: [10.52783/tjpt.v44.i2.150](https://doi.org/10.52783/tjpt.v44.i2.150).
- [11] R. Du, Y. Chen, T. Li, L. Shi, Z. Fei, and Y. Li, "Discrimination of Breast Cancer Based on Ultrasound Images and Convolutional Neural Network," *J. Oncol.*, vol. 2022, 2022, doi: [10.1155/2022/7733583](https://doi.org/10.1155/2022/7733583).
- [12] M. D. Ali *et al.*, "Breast Cancer Classification through Meta-Learning Ensemble Technique Using Convolution Neural Networks," *Diagnostics*, vol. 13, no. 13, 2023, doi: [10.3390/diagnostics13132242](https://doi.org/10.3390/diagnostics13132242).
- [13] A. Al Tawil, A. Shaban, and L. Almazaydeh, "A comparative analysis of convolutional neural networks for breast cancer prediction," *Int. J. Electr. Comput. Eng.*, vol. 14, no. 3, pp. 3406–3414, 2024, doi: [10.11591/ijece.v14i3.pp3406-3414](https://doi.org/10.11591/ijece.v14i3.pp3406-3414).
- [14] O. Özkaraca *et al.*, "Multiple Brain Tumor Classification with Dense CNN Architecture Using Brain MRI Images," *Life*, vol. 13, no. 2, 2023, doi: [10.3390/life13020349](https://doi.org/10.3390/life13020349).
- [15] S. Arooj *et al.*, "Breast Cancer Detection and Classification Empowered With Transfer Learning," *Front. Public Heal.*, vol. 10, no. July, pp. 1–18, 2022, doi: [10.3389/fpubh.2022.924432](https://doi.org/10.3389/fpubh.2022.924432).
- [16] M. Zourhri, S. Hamida, N. Akouz, B. Cherradi, H. Nhaila, and M. El Khaili, "Deep Learning Technique for Classification of Breast Cancer using Ultrasound Images," *2023 3rd Int. Conf. Innov. Res. Appl. Sci. Eng. Technol. IRASET 2023*, no. April 2024, 2023, doi: [10.1109/IRASET57153.2023.10153069](https://doi.org/10.1109/IRASET57153.2023.10153069).
- [17] A. AlZoubi, F. Lu, Y. Zhu, T. Ying, M. Ahmed, and H. Du, "Classification of breast lesions in ultrasound images using deep convolutional neural networks: transfer learning versus automatic architecture design," *Med. Biol. Eng. Comput.*, vol. 62, no. 1, pp. 135–149, 2024, doi: [10.1007/s11517-023-02922-y](https://doi.org/10.1007/s11517-023-02922-y).
- [18] V. Azevedo, C. Silva, and I. Dutra, "Quantum transfer learning for breast cancer detection," *Quantum Mach. Intell.*, vol. 4, no. 1, 2022, doi: [10.1007/s42484-022-00062-4](https://doi.org/10.1007/s42484-022-00062-4).
- [19] M. Alruwaili and W. Gouda, "Automated Breast Cancer Detection Models Based on Transfer Learning," *Sensors*, vol. 22, no. 3, 2022, doi: [10.3390/s22030876](https://doi.org/10.3390/s22030876).
- [20] A. W. Salehi *et al.*, "A Study of CNN and Transfer Learning in Medical Imaging: Advantages, Challenges, Future Scope," *Sustain.*, vol. 15, no. 7, 2023, doi: [10.3390/su15075930](https://doi.org/10.3390/su15075930).
- [21] F. Uysal and M. M. Köse, "Classification of Breast Cancer Ultrasound Images with Deep Learning-Based Models †," *Eng. Proc.*, vol. 31, no. 1, 2022, doi: [10.3390/ASEC2022-13791](https://doi.org/10.3390/ASEC2022-13791).
- [22] N. Matondo-Mvula and K. Elleithy, "Breast Cancer Detection with Quantvolutional Neural Networks," *Entropy*, vol. 26, no. 8, 2024, doi: [10.3390/e26080630](https://doi.org/10.3390/e26080630).
- [23] J. Yang *et al.*, "MedMNIST v2 - A large-scale lightweight benchmark for 2D and 3D biomedical image classification," *Sci. Data*, vol. 10, no. 1, pp. 1–10, 2023, doi: [10.1038/s41597-022-01721-8](https://doi.org/10.1038/s41597-022-01721-8).
- [24] A. B. M. A. Hossain, J. K. Nisha, and F. Johora, "Breast Cancer Classification from Ultrasound Images using VGG16 Model based Transfer Learning," *Int. J. Image, Graph. Signal Process.*, vol. 15, no. 1, pp. 12–22, 2023, doi: [10.5815/ijigsp.2023.01.02](https://doi.org/10.5815/ijigsp.2023.01.02).
- [25] M. Krichen, "Convolutional Neural Networks: A Survey," *Computers*, vol. 12, no. 8, pp. 1–41, 2023, doi: [10.3390/computers12080151](https://doi.org/10.3390/computers12080151).
- [26] J. Alyami *et al.*, "Cloud Computing-Based Framework for Breast Tumor Image Classification Using Fusion of AlexNet and GLCM Texture Features with Ensemble Multi-Kernel Support Vector Machine (MK-SVM)," *Comput. Intell. Neurosci.*, vol. 2022, 2022, doi: [10.1155/2022/7403302](https://doi.org/10.1155/2022/7403302).
- [27] S. Mohapatra, S. Muduly, S. Mohanty, J. V. R. Ravindra, and S. N. Mohanty, "Evaluation of deep learning models for detecting breast cancer using histopathological mammograms Images," *Sustain. Oper. Comput.*, vol. 3, no. March, pp. 296–302, 2022, doi: [10.1016/j.susoc.2022.06.001](https://doi.org/10.1016/j.susoc.2022.06.001).
- [28] P. Ashwini, N. Suguna, and N. Vadivelan, "Detection and classification of breast cancer types using VGG16 and ResNet50 deep learning techniques," *Int. J. Electr. Comput. Eng.*, vol. 14, no. 5, pp. 5481–5488, 2024, doi: [10.11591/ijece.v14i5.pp5481-5488](https://doi.org/10.11591/ijece.v14i5.pp5481-5488).
- [29] D. Shah, M. A. U. Khan, M. Abrar, and M. Tahir, "Optimizing Breast Cancer Detection With an Ensemble Deep Learning Approach," *Int. J. Intell. Syst.*, vol. 2024, no. 1, 2024, doi: [10.1155/2024/5564649](https://doi.org/10.1155/2024/5564649).
- [30] J. Lee, J. Park, and Y. Lee, "Towards Efficient Cancer Detection on Mobile Devices," *IEEE Access*, vol. 13, no. February, pp. 34613–34626, 2025, doi: [10.1109/ACCESS.2025.3543838](https://doi.org/10.1109/ACCESS.2025.3543838).
- [31] Y. F. Khan, A. Runani, and B. Ahmed Mir, "Swarm-driven fine-tuned hybrid transfer learning architecture on breast ultrasound scans for advanced prognostic," *Int. J. Inf. Technol.*, no. December 2024, 2024, doi: [10.1007/s41870-024-02329-4](https://doi.org/10.1007/s41870-024-02329-4).
- [32] T. Yang and Y. Ying, "AUC Maximization in the Era of Big Data and AI: A Survey," *ACM Comput. Surv.*, vol. 55, no. 8, 2022, doi: [10.1145/3554729](https://doi.org/10.1145/3554729).