

Breast Cancer Detection Using EfficientNetV2 Variants and Data Augmentation: A Comparative Study

^{1,*}Erin Eka Citra, ²Siti Mutmainah, ³Bambang Hermanto

¹ Ilmu Komputer, Universitas Lampung, Jl. Prof. Dr. Ir. Sumantri Brojonegoro, Bandar Lampung, Indonesia

² Ilmu Komputer, Universitas Muhammadiyah Bima, Jln. Anggrek No. 16 Ranggo. Na'e, Kota Bima, Indonesia

³ Ilmu Komputer, Universitas Lampung, Jl. Prof. Dr. Ir. Sumantri Brojonegoro, Bandar Lampung, Indonesia

Abstrak — Kanker merupakan penyebab utama kematian kedua di dunia yang menyebabkan sekitar 9,6 juta kematian. Deteksi kanker dan penanganannya sedini mungkin dapat menurunkan angka kematian. Metode *deep learning* terbukti mampu mengenali pola dalam citra medis dan memberikan hasil klasifikasi yang akurat, EfficientNet merupakan salah satu metode *deep learning*. Penelitian ini bertujuan untuk mengeksplorasi penggunaan berbagai varian EfficientNetV2, yaitu EfficientNetV2-S, EfficientNetV2-M, dan EfficientNetV2-L untuk mendeteksi kanker payudara berdasarkan citra medis. Dataset yang digunakan yakni gambar USG wanita berusia antara 25 dan 75 tahun sebanyak 600 wanita, dengan total 780 gambar USG yang memiliki ukuran rata-rata 500×500 piksel dalam format PNG. Setiap gambar dalam dataset ini diklasifikasikan ke dalam tiga label yaitu normal, jinak (*benign*), dan ganas (*malignant*). Penelitian ini mendapatkan hasil akurasi terbaik pada model EfficientNetV2-L dibandingkan model EfficientNetV2-S dan EfficientNetV2-M. Nilai akurasi pelatihan yang didapatkan sebesar 89% dan nilai akurasi validasi sebesar 86% dengan nilai loss pelatihan sebesar 0.30 dan nilai loss validasi sebesar 0.37. Berdasarkan hasil tersebut, penelitian ini memiliki potensi sebagai solusi pendukung keputusan medis yang efisien dalam praktik klinis sehari-hari untuk deteksi kanker payudara.

Kata Kunci: Deteksi Kanker; EfficientNetV2; Kanker Payudara; Citra Medis.

Abstract — Cancer is the second leading cause of death globally, accounting for approximately 9.6 million fatalities. Early cancer detection and timely intervention can significantly reduce mortality rates. Deep learning methods have demonstrated the ability to recognize patterns in medical imaging and deliver accurate classification results, with EfficientNet being one such deep learning method. This study aims to explore the application of various EfficientNetV2 variants—namely EfficientNetV2-S, EfficientNetV2-M, and EfficientNetV2-L—for breast cancer detection using medical images. The dataset consists of breast ultrasound images from 600 women aged between 25 and 75 years, totaling 780 ultrasound images with an average size of 500×500 pixels in PNG format. Each image in the dataset is classified into three categories: normal, benign, and malignant. The study achieved the highest accuracy with the EfficientNetV2-L model compared to EfficientNetV2-S and EfficientNetV2-M, yielding a training accuracy of 89% and a validation accuracy of 86%, with training and validation loss values of 0.30 and 0.37, respectively. Based on these findings, this research holds potential as an efficient medical decision-making support tool in daily clinical practice for early breast cancer detection.

Keywords: Early Detection; EfficientNet; Breast Cancer; Medical Image.

* Corresponding author :

Erin Eka Citra

Universitas Lampung, Bandar Lampung, Indonesia

erinekacitra@fmipa.unila.ac.id

1. PENDAHULUAN

Organisasi Kesehatan Dunia (WHO), Kanker merupakan penyebab utama kematian kedua di dunia, menyebabkan sekitar 9,6 juta kematian. Salah satu kanker yang memiliki tingkat kejadian dan kematian yang tinggi yaitu kanker payudara. Kanker payudara merupakan penyakit yang disebabkan pertumbuhan sel-sel payudara yang tidak normal sehingga membentuk tumor. Pada tahun 2022 terdapat 2,3 juta wanita yang terdiagnosa menderita kanker payudara dan 670.000 kematian di seluruh dunia [1]. Kanker payudara merupakan jenis kanker dengan tingkat kejadian tertinggi di Indonesia. Data Global Cancer

Observatory (GLOBOCAN) di Indonesia 2020 menyebutkan jumlah kasus baru kanker payudara mencapai sekitar 68.858 kasus per tahun dengan angka kematian sebesar 22.430 kasus [2].

Tingginya angka kematian disebabkan beberapa faktor seperti terbatasnya fasilitas pengobatan yang berkualitas dan tepat waktu, kurangnya akses terhadap teknologi diagnostic. Deteksi kanker dan penanganannya sedini mungkin dapat menurunkan angka kematian. Teknologi diagnostic dapat membantu *skrining, staging, monitoring* pengobatan hingga pengawasan pasien kanker dalam jangka panjang [3].


Semakin berkembangnya teknologi banyak metode berbasis kecerdasan buatan yang telah dikembangkan untuk membantu mendeteksi kanker secara lebih akurat dan efisien. Beberapa penelitian sebelumnya menggunakan metode *machine learning* dan *deep learning* dalam mendeteksi berbagai jenis termasuk kanker otak, payudara, paru-paru, dan kulit, menunjukkan kinerja yang baik dalam deteksi dan klasifikasi [8]. Metode tersebut memanfaatkan teknik citra medis seperti X-ray, MRI, mamografi, USG dan CT scan untuk diagnosis yang akurat [4]-[11]. Citra medis berperan penting dalam deteksi dan penanganan kanker, terutama untuk kanker payudara [12]-[13].

Metode *deep learning* seperti *Convolutional Neural Networks* (CNN) terbukti mampu mengenali pola dalam citra medis dan memberikan hasil klasifikasi yang akurat. EfficientNet merupakan keluarga CNN yang dirancang untuk skala mendalam, lebar, dan resolusi yang optimal, sehingga mencapai akurasi terbaik dengan parameter yang lebih sedikit [14]-[15]. EfficientNet metode *deep learning* yang dikembangkan oleh Google. Beberapa varian dari EfficientNet yaitu EfficientNetV2-S, EfficientNetV2-M, dan EfficientNetV2-L, masing-masing memiliki tingkat kompleksitas dan kapasitas yang berbeda dalam memproses data citra medis [16]-[18].

Penelitian ini bertujuan membandingkan kinerja berbagai varian EfficientNetV2 (EfficientNetV2-S, EfficientNetV2-M, dan EfficientNetV2-L) dalam mendeteksi kanker payudara berdasarkan citra medis. Fokus utama adalah untuk mengevaluasi efektivitas masing-masing varian dalam hal akurasi, presisi, recall, dan efisiensi komputasi. Penelitian ini diharapkan dapat mengidentifikasi varian model yang paling optimal untuk digunakan sebagai sistem diagnosis kanker payudara yang cepat, akurat, dan hemat sumber daya. Hasil penelitian ini berpotensi memberikan kontribusi yang signifikan dalam pengembangan teknologi deteksi kanker yang lebih handal dan dapat diaplikasikan secara luas, terutama di fasilitas kesehatan dengan sumber daya yang terbatas.

2. METODOLOGI PENELITIAN

Metodologi penelitian ini dirancang untuk mengevaluasi dan membandingkan performa tiga varian model EfficientNetV2 (EfficientNetV2-S, EfficientNetV2-M, dan EfficientNetV2-L) dalam mendeteksi kanker payudara berbasis citra medis. Proses penelitian digambarkan melalui diagram alur pada Gambar 1, yang terdiri dari beberapa tahapan mulai dari pengumpulan dataset, preprocessing, split dataset, pemodelan, evaluasi dan prediksi tes. Tahapan penelitian merupakan rancangan orisinal penulis dan disusun untuk merepresentasikan alur berpikir dan tahapan eksperimen yang dilakukan secara sistematis.



Gambar 1. Tahapan Penelitian

2.1. DataSet

Data yang digunakan dalam penelitian ini adalah kumpulan gambar USG payudara yang dikumpulkan pada tahun 2018. Data tersebut mencakup gambar USG wanita berusia antara 25 dan 75 tahun. Jumlah pasien dalam dataset ini adalah 600 wanita, dengan total 780 gambar USG yang memiliki ukuran rata-rata 500×500 piksel dalam format PNG. Setiap gambar dalam dataset ini diklasifikasikan ke dalam tiga label yaitu normal, jinak (*benign*), dan ganas (*malignant*).

2.2. Preprocessing Data


Preprocessing data mencakup beberapa langkah penting seperti normalisasi citra, peningkatan kualitas citra menggunakan teknik *filtering*, dan augmentasi data. Proses *filtering* dilakukan untuk memastikan kualitas gambar yang baik dan label yang valid yang akan digunakan dalam training model. Proses ini mencakup penghapusan gambar duplikat, gambar yang buram atau memiliki gangguan artefak yang signifikan, dan gambar dengan anotasi yang tidak konsisten. Teknik augmentasi yang digunakan mencakup rotasi, flipping, dan perubahan kontras untuk memperkaya data pelatihan. Teknik augmentasi data diterapkan untuk meningkatkan variasi dan jumlah data pelatihan, mengingat keterbatasan umum dataset medis. Proses ini bertujuan untuk mengurangi noise dan meningkatkan akurasi dan generalisasi model dalam mendeteksi pola pada citra kanker payudara.

2.3. Split Dataset

Dataset dibagi menjadi dua bagian utama: data pelatihan dan data pengujian. Dataset dibagi menjadi data pelatihan dan data validasi dengan parameter `validation_split = 0.2`, pembagian dataset sebesar 80% untuk pelatihan dan 20% untuk validasi, hal tersebut dilakukan guna memastikan model mendapatkan cukup data untuk belajar sekaligus diuji dengan data yang belum pernah dilihat sebelumnya.

2.4. Pemodelan

Pada tahap pemodelan menggunakan arsitektur EfficientNetV2-S yang dikenal ringan dan efisien untuk klasifikasi gambar. Model diinisialisasi dengan bobot yang ditraining sebelumnya dari ImageNet untuk memanfaatkan fitur awal yang dipelajari. Selanjutnya, fine-tuning dilakukan dengan membuka beberapa layer terakhir untuk menyesuaikan model dengan dataset yang digunakan. Layer klasifikasi tambahan ditambahkan di atas model dasar, yang terdiri dari dense layer, dropout, dan softmax sebagai output. Model disusun menggunakan Adam's optimizer, categorical crossentropy loss function, dan metrik akurasi, dan dilatih menggunakan teknik callback seperti EarlyStopping dan ModelCheckpoint untuk menghindari overfitting dan menyimpan model terbaik. Pemodelan dilakukan dengan menggunakan tiga varian EfficientNetV2, yaitu EfficientNetV2-S, EfficientNetV2-M, dan EfficientNetV2-L.



Gambar 2. Struktur MBConv dan Fused-MBConv [17]

Struktur dari MBConv dan Fused-MBConv pada EfficientNetV2 dapat dilihat pada Gambar 2. Struktur EfficientNetV2 menerapkan kombinasi blok MBConv (*Mobile Inverted Bottleneck Convolution*) dengan nilai rasio ekspansi yang diminimalkan dan modul Fused-MBConv yang disisipkan pada lapisan awal. Selain itu, arsitektur ini mengoptimalkan penggunaan kernel konvolusi 3x3 yang lebih kompak dengan penerapan secara hierarkis untuk meningkatkan efisiensi komputasi. Desain MBConv dan Fused-MBConv dalam EfficientNetV2 dibedakan oleh konfigurasi lapisan konvolusinya. MBConv mengadopsi *depthwise convolution* 3x3 yang dikombinasikan dengan konvolusi 1x1, sedangkan Fused-MBConv menggantikan kedua lapisan tersebut dengan konvolusi 3x3 tunggal untuk mengurangi kompleksitas komputasi [17].

2.5. Evaluasi

Evaluasi model dilakukan dengan mengukur metrik performa seperti akurasi, sensitivitas, spesifisitas, dan *Area Under the Curve* (AUC). Selain itu, dilakukan komparasi dengan model lain untuk mengetahui keunggulan dan kekurangan EfficientNet dalam mendeteksi kanker payudara. Tahap terakhir dalam penelitian ini adalah prediksi menggunakan data uji. Model yang telah dilatih akan diuji dengan data yang belum pernah dilihat sebelumnya untuk mengetahui kemampuannya dalam mengklasifikasikan citra ke dalam kategori normal, jinak, atau ganas. Hasil prediksi ini dianalisis untuk memastikan bahwa model memiliki kinerja yang baik dalam mendeteksi kanker payudara secara otomatis.

2.6. Prediksi dan Pengujian

Model yang telah dilatih akan diuji dengan data uji yang belum pernah dilihat sebelumnya. Hasil prediksi model dianalisis untuk memastikan keakuratan klasifikasi citra ke dalam kategori normal, jinak, atau ganas. Selain itu, model terbaik akan diidentifikasi berdasarkan performa terbaik yang diperoleh dari hasil evaluasi.

3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan tiga varian model EfficientNetV2, yaitu EfficientNetV2-S, EfficientNetV2-M, dan EfficientNetV2-L. Masing-masing model dilakukan pengujian secara terpisah untuk melihat performa klasifikasi terhadap gambar USG payudara yang telah dikumpulkan. Bagian ini meliputi implementasi dataset, preprocessing data, pengaturan parameter pelatihan, augmentasi data, pemodelan, pelatihan, evaluasi model, dan perbandingan performa ketiga model EfficientNetV2.

3.1. Pengolahan Data

3.1.1. Implementasi Dataset

Dataset USG payudara digunakan dalam format direktori yang sudah diklasifikasikan ke dalam tiga label yaitu normal, jinak (*benign*), dan ganas (*malignant*). Dataset memiliki resolusi 500×500 piksel, pada tahap training dilakukan downsampling menjadi ukuran 80×80 piksel. Downsampling ini dilakukan untuk mengurangi beban komputasi, efisiensi memori dan waktu pelatihan, mengingat model yang digunakan (EfficientNetV2-S/M/L) cukup kompleks dan membutuhkan sumber daya besar.

3.1.2. Preprocessing Data dan Augmentasi Data

Pada tahap ini terdapat dua aspek utama yakni normalisasi piksel citra dan augmentasi data. Normalisasi dilakukan dengan mengubah nilai piksel citra menjadi skala antara 0 hingga 1, yaitu dengan membagi nilai piksel dengan 255 yang bertujuan untuk mempercepat proses konvergensi selama pelatihan model dan mencegah nilai input yang terlalu besar yang dapat menghambat proses propagasi pada jaringan syaraf.

Augmentasi data dilakukan untuk meningkatkan generalisasi model melalui diversifikasi sampel latih, sehingga memungkinkan model mengenali pola citra yang lebih beragam sekaligus mengurangi risiko *overfitting*. Augmentasi dilakukan menggunakan modul Sequential dari Keras yang terdiri atas lapisan-lapisan transformasi acak seperti *RandomFlip*, *RandomRotation*, *RandomZoom*, *RandomContrast*, *RandomBrightness*, dan *RandomTranslation*. *RandomFlip* menggunakan mode horizontal dan vertikal, *RandomRotation* menggunakan rotasi acak hingga 30%, *RandomZoom* menggunakan perbesaran/pengecilan hingga 30%, *RandomContrast* dan *RandomBrightness* menggunakan penyesuaian kontras dan kecerahan dengan rentang intensitas 0.2, dan *RandomTranslation* menggunakan translasi acak 10% pada sumbu X dan Y. Kode program 1 merupakan implementasi dari augmentasi data yang digunakan.

```
data_augmentation = keras.Sequential([
    layers.RandomFlip("horizontal_and_vertical"),
    layers.RandomRotation(0.3),
    layers.RandomZoom(0.3),
    layers.RandomContrast(0.2),
    layers.RandomBrightness(0.2),
    layers.RandomTranslation(0.1, 0.1)
])
```

Kode Program 1. Kode program augmentasi data

Pipeline augmentasi ini dilakukan secara *real-time* pada setiap *batch* selama pelatihan, sehingga variasi citra berbeda terbentuk di setiap *epoch*. Pendekatan ini menciptakan lingkungan pelatihan yang dinamis tanpa perlu menambah jumlah data secara fisik, sehingga mengoptimalkan pemanfaatan sumber daya komputasi.


3.1.3. Pengaturan Parameter Pelatihan

Parameter pelatihan model dilakukan dengan pengaturan batch size sebesar 128 dan *mixed_precision policy* yang diaktifkan untuk efisiensi GPU. *Optimizer* yang digunakan adalah Adam dengan learning rate default, sementara *loss function* yang digunakan adalah *categorical_crossentropy* karena klasifikasi terdiri dari tiga kelas. *Callback* seperti *EarlyStopping* dan *ModelCheckpoint* diterapkan untuk menghentikan pelatihan secara otomatis jika akurasi validasi tidak meningkat dan menyimpan model terbaik.

3.2. Hasil Pengujian


3.2.1. Pemodelan dengan EfficientNetV2-S

Model pertama yang digunakan yakni EfficientNetV2-S. Model ini diambil dari *TensorFlow Hub*, kemudian dikombinasikan dengan lapisan tambahan yaitu *GlobalAveragePooling2D*, *Dropout*, dan *Dense Layer* untuk klasifikasi tiga label dataset. Model dilatih menggunakan 15 epoch dengan hasil akurasi pelatihan mencapai 91% dan akurasi validasi mencapai 85%. Grafik akurasi *loss* menunjukkan tren peningkatan yang stabil tanpa tanda *overfitting* yang signifikan.



Gambar 3. Grafik nilai *accuracy* dan nilai *loss* data latih dan validasi EfficientNetV2-S

Gambar 3 memperlihatkan visualisasi tren akurasi dan *loss* klasifikasi model EfficientNetV2-S secara berurutan, mulai dari nilai tertinggi hingga titik terendah. Berdasarkan hasil visualisasi pada Gambar 3, dapat dilihat dinamika pembelajaran model EfficientNetV2-S di mana akurasi pelatihan mengalami tren peningkatan, sementara akurasi validasi cenderung stagnan. Di sisi lain, *loss* pelatihan terus menurun secara konsisten, sedangkan *loss* validasi hanya turun pada fase awal, lalu mengalami fluktuasi. Pola ini menunjukkan bahwa model mampu beradaptasi optimal dengan data pelatihan, tetapi kurang mampu melakukan generalisasi pada data validasi. Kondisi ini merupakan indikasi terjadinya *overfitting*, di mana terjadi disparitas signifikan antara performa pelatihan dan validasi, menandakan model terlalu spesifik mempelajari *noise* atau pola unik pada data pelatihan.




Gambar 4. Hasil Pengujian. Tulisan *predicted* dibawah gambar menunjukkan hasil prediksi dari gambar, sedangkan tulisan *true* menunjukkan nama asli dari gambar yang diprediksi.

Gambar 4 merupakan contoh hasil pengujian deteksi penyakit kanker payudara menggunakan arsitektur EfficientNetV2-S. Berdasarkan hasil pengujian dapat dilihat keakuratan arsitektur EfficientNetV2-S dalam memprediksi penyakit kanker payudara dengan menampilkan hasil prediksi dan nama asli dari kelas penyakit kanker payudara. Deteksi yang dilakukan yakni sebanyak 9 (sembilan) gambar dengan total sebanyak 7 kali benar dalam memprediksi dan 2 kali salah dalam memprediksi.


3.2.2. Pemodelan dengan EfficientNetV2-M

Model kedua yang digunakan yakni EfficientNetV2-M. Model ini memiliki arsitektur yang lebih kompleks dibandingkan model EfficientNetV2-S. Proses pelatihan dilakukan dengan konfigurasi yang sama, namun hasil akurasi pelatihan mengalami penurunan hingga 86% dan akurasi validasi sebesar 83%. Namun proses pelatihan sedikit lebih lama karena kompleksitas model pada EfficientNetV2-M. Hasil menunjukkan bahwa arsitektur ini tidak lebih tinggi nilai akurasinya jika dibandingkan EfficientNetV2-S dalam mengenali fitur-fitur yang lebih kompleks dalam citra USG.



Gambar 5. Grafik nilai *accuracy* dan nilai *loss* data latih dan validasi EfficientNetV2-M

Pada Gambar 5 menunjukkan visualisasi tren akurasi dan loss klasifikasi model EfficientNetV2-M secara berurutan, mulai dari nilai tertinggi hingga titik terendah. Berdasarkan hasil visualisasi pada Gambar 5, dapat dilihat dinamika pembelajaran model EfficientNetV2-M di mana akurasi pelatihan mengalami tren peningkatan secara konsisten, dan akurasi validasi juga cukup tinggi sehingga tidak ada perbedaan yang signifikan antara akurasi pelatihan dan validasi. Di sisi lain, loss pelatihan turun drastis kemudian terus menurun secara konsisten, sedangkan *loss* validasi menurun secara stabil dan tidak fluktuatif seperti grafik pada EfficientNetV2-S. Kondisi ini menunjukkan bahwa model lebih bagus dan stabil. Nilai akurasi yang tinggi dan *loss* yang rendah pada data pelatihan dan validasi menunjukkan generalisasi yang baik dan tidak terjadi *overfitting*.




Gambar 6. Hasil Pengujian. Tulisan *predicted* dibawah gambar menunjukkan hasil prediksi dari gambar, sedangkan tulisan *true* menunjukkan nama asli dari gambar yang diprediksi.

Gambar 6 merupakan contoh hasil pengujian deteksi penyakit kanker payudara menggunakan arsitektur EfficientNetV2-M. Berdasarkan hasil pengujian dapat dilihat keakuratan arsitektur EfficientNetV2-M dalam memprediksi penyakit kanker payudara dengan menampilkan hasil prediksi dan nama asli dari kelas penyakit kanker payudara. Deteksi yang dilakukan yakni sebanyak 9 (sembilan) gambar dengan total sebanyak 6 kali benar dalam memprediksi dan 3 kali salah dalam memprediksi.


3.2.3. Pemodelan dengan EfficientNetV2-L

Model ketiga yang diujikan yakni EfficientNetV2-L. Model ini merupakan model dengan versi paling kompleks dari model EfficientNetV2-S dan EfficientNetV2-M. Proses pelatihan dilakukan dengan konfigurasi yang sama, namun hasil akurasi pelatihan juga mengalami penurunan hingga 89% dan akurasi validasi sebesar 86% jika dibandingkan EfficientNetV2-S, tetapi mengalami sedikit kenaikan jika dibandingkan EfficientNetV2-M. Namun proses pelatihan sedikit lebih lama karena kompleksitas model pada EfficientNetV2-L.



Gambar 7. Grafik nilai *accuracy* dan nilai *loss* data latih dan validasi EfficientNetV2-L

Gambar 7 memperlihatkan visualisasi tren akurasi dan *loss* klasifikasi model EfficientNetV2-L secara berurutan, mulai dari nilai tertinggi hingga titik terendah. Berdasarkan hasil visualisasi pada Gambar 7, dapat dilihat dinamika pembelajaran model EfficientNetV2-L di mana akurasi pelatihan mengalami tren peningkatan secara konsisten, dan akurasi validasi juga meningkat bahkan lebih tinggi dari akurasi pelatihan di beberapa titik seperti pada *epoch* 6-7. Hasil akurasi tersebut menunjukkan bahwa model tidak *overfitting* maupun *underfitting*, dan nilai validasi yang tinggi menunjukkan kemampuan generalisasi yang bagus pada data baru sehingga model sangat ideal. Di sisi lain, *loss* pelatihan turun konsisten, dan *loss* validasi menurun secara stabil bahkan lebih rendah dari *loss* pelatihan di beberapa titik. Nilai akurasi yang tinggi pada pelatihan dan validasi serta *loss* yang stabil dan rendah menunjukkan bahwa ini memiliki performa yang paling stabil dan terbaik dibandingkan model EfficientNetV2-S dan EfficientNetV2-M.



Gambar 8. Hasil Pengujian. Tulisan *predicted* dibawah gambar menunjukkan hasil prediksi dari gambar, sedangkan tulisan *true* menunjukkan nama asli dari gambar yang diprediksi.

Gambar 8 merupakan contoh hasil pengujian deteksi penyakit kanker payudara menggunakan arsitektur EfficientNetV2-L. Berdasarkan hasil pengujian dapat dilihat keakuratan arsitektur EfficientNetV2-L dalam memprediksi penyakit kanker payudara dengan menampilkan hasil prediksi dan nama asli dari kelas penyakit kanker payudara. Deteksi yang dilakukan yakni sebanyak 9 (sembilan) gambar dengan total sebanyak 7 kali benar dalam memprediksi dan 2 kali salah dalam memprediksi.

Tabel 1. Rangkuman hasil akurasi dan loss data latih dan validasi

No	Model	Data Latih		Data Validasi		Hasil
		Loss	Acc (%)	Loss	Acc (%)	
1	EfficientNetV2-S	0.28	91	0.33	85	Overfitting ringan
2	EfficientNetV2-M	0.32	86	0.42	83	Seimbang dan stabil
3	EfficientNetV2-L	0.30	89	0.37	86	Paling Optimal

4. KESIMPULAN

Penelitian ini mendapatkan hasil deteksi untuk penyakit kanker payudara dengan tiga varian EfficientNetV2, yaitu EfficientNetV2-S, EfficientNetV2-M, dan EfficientNetV2-L berdasarkan citra medis. Komparasi antara ketiga varian model yang dilakukan dapat dilihat pada Tabel 1, yakni model terbaik didapatkan dari EfficientNetV2-L dengan nilai akurasi pelatihan sebesar 89% dan nilai akurasi validasi sebesar 86% dengan nilai loss pelatihan sebesar 0.30 dan nilai *loss* validasi sebesar 0.37. Hasil akurasi tersebut menunjukkan bahwa model ideal, tidak *overfitting* maupun *underfitting*, dan nilai *loss* yang stabil dan rendah menunjukkan bahwa ini memiliki performa yang paling stabil dan terbaik dibandingkan model EfficientNetV2-S dan EfficientNetV2-M. Berdasarkan hasil prediksi yang diperoleh model EfficientNetV2-S dan EfficientNetV2-L mendapatkan hasil prediksi yang lebih baik dibandingkan EfficientNetV2-M. Hasil prediksi yang didapatkan yakni dari sembilan gambar yang diprediksi, model berhasil menebak 7 gambar dengan benar dan 2 gambar yang tidak tepat. Penelitian selanjutnya dapat mengeksplorasi jenis augmentasi dan model lain yang lebih canggih.

5. DAFTAR PUSTAKA

- [1] Organisasi Kesehatan Dunia (World Health Organization), “Cancer,” Organisasi Kesehatan Dunia (World Health Organization). [Daring]. Tersedia pada: https://www.who.int/health-topics/cancer#tab=tab_1
- [2] Sehat Negeriku, “Kanker Payudara Paling Banyak di Indonesia, Kemenkes Targetkan Pemerataan Layanan Kesehatan,” [/sehatnegeriku.kemkes.go.id](https://sehatnegeriku.kemkes.go.id). Diakses: 5 Maret 2025. [Daring]. Tersedia pada: <https://sehatnegeriku.kemkes.go.id/baca/umum/20220202/1639254/kanker-payudaya-paling-banyak-di-indonesia-kemenkes-targetkan-pemerataan-layanan-kesehatan/>
- [3] S. P. K. Malhotra, “MEDICAL IMAGING IN THE DETECTION OF CANCER,” 2020. [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:235261125>
- [4] X. Jiang, Z. Hu, S. Wang, dan Y. Zhang, “Deep learning for medical image-based cancer diagnosis,” *Cancers*, vol. 15, no. 14, hlm. 3608, 2023.
- [5] S. Maurya, S. Tiwari, M. C. Mothukuri, C. M. Tangeda, R. N. S. Nandigam, dan D. C. Addagiri, “A review on recent developments in cancer detection using Machine Learning and Deep learning models,” *Biomedical Signal Processing and Control*, vol. 80, hlm. 104398, Feb 2023, doi: 10.1016/j.bspc.2022.104398.
- [6] T. Saba, “Recent advancement in cancer detection using machine learning: Systematic survey of decades, comparisons and challenges,” *Journal of Infection and Public Health*, vol. 13, no. 9, hlm. 1274–1289, Sep 2020, doi: 10.1016/j.jiph.2020.06.033.
- [7] U. R. P. Nasution, R. Rahmat, T. Munthe, M. Elveny, R. Nurhasanah, dan T. Lini, “Skin cancer image classification based on cancer malignancy on deep convolutional neural network (DCNN),” Jan 2024, hlm. 020017. doi: 10.1063/5.0200113.
- [8] T. Sood, R. Bhatia, dan P. Khandnor, “Cancer Detection Based on Medical Image Analysis with the Help of Machine Learning and Deep learning Techniques: A Systematic Literature Review,” *Current Medical Imaging Reviews*, vol. 19, no. 13, hlm. 1487–1522, 2023.
- [9] A. R. M. Al-shamasneh dan U. H. B. Obaidallah, “Artificial Intelligence Techniques for Cancer Detection and Classification: Review Study,” *ESJ*, vol. 13, no. 3, Jan 2017, doi: 10.19044/esj.2016.v13n3p342.
- [10] I. Ahmad dan F. Alqurashi, “Early cancer detection using deep learning and medical imaging: A survey,” *Critical Reviews in Oncology/Hematology*, vol. 204, hlm. 104528, Des 2024, doi: 10.1016/j.critrevonc.2024.104528.
- [11] F. Y. Shih dan J. S. Tse, “Medical Image Processing Technology for Diagnosing and Treating Cancers,” *Recent Patents on Biomedical Engineering (Discontinued)*, vol. 2, no. 2, hlm. 141–147, 2009.
- [12] R. Jalloul, H. Chethan, dan R. Alkhatib, “A review of machine learning techniques for the classification and detection of breast cancer from medical images,” *Diagnostics*, vol. 13, no. 14, hlm. 2460, 2023.
- [13] Y. Lu, J.-Y. Li, Y.-T. Su, dan A.-A. Liu, “A review of breast cancer detection in medical images,” *2018 IEEE Visual Communications and Image Processing (VCIP)*, hlm. 1–4, 2018.
- [14] M. Tan dan Q. Le, “Efficientnet: Rethinking model scaling for convolutional neural networks,” dipresentasikan pada International conference on machine learning, PMLR, 2019, hlm. 6105–6114.
- [15] A. Wongpanich dkk., “Training EfficientNets at supercomputer scale: 83% ImageNet top-1

- accuracy in one hour,” dipresentasikan pada 2021 IEEE International Parallel and Distributed Processing Symposium Workshops (IPDPSW), IEEE, 2021, hlm. 947–950.
- [16] C.-C. Wang, C.-T. Chiu, dan J.-Y. Chang, “Efficientnet-elite: Extremely lightweight and efficient cnn models for edge devices by network candidate search,” *Journal of Signal Processing Systems*, vol. 95, no. 5, hlm. 657–669, 2023.
- [17] M. Tan dan Q. Le, “Efficientnetv2: Smaller models and faster training,” dipresentasikan pada International conference on machine learning, PMLR, 2021, hlm. 10096–10106.
- [18] J. Rengel, M. Santos, dan R. Pandit, “EfficientNet architecture family analysis on railway track defects,” dipresentasikan pada International Conference on Intelligent Data Engineering and Automated Learning, Springer, 2022, hlm. 474–481.