



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 4 No. 2 (2025) pp: 5947-5955

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Analisis Komparatif CNN dan Transfer Learning untuk Prediksi Dini Kanker Payudara Berbasis Deep Learning

Noufal Zaidan¹, Erick Markus Seka², Resta Axellee³, Muhammad Haikal Syahputra⁴, Giatika Chrisnawati⁵, Yayan Hendrian⁶

^{1,2,3,4,5,6} Program Studi Informatika, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika
¹noufal1305@gmail.com, ²sekaflores04@gmail.com, ³restaaxellee@gmail.com, ⁴haykals12@gmail.com,
⁵giatika.gcw@bsi.ac.id, ⁶yayan.yhn@bsi.ac.id

Abstrak

Kanker payudara tetap menjadi penyebab utama kematian di kalangan wanita secara global. Mendeteksi penyakit pada tahap awal secara signifikan meningkatkan keberhasilan pengobatan dan tingkat kelangsungan hidup. Studi ini bertujuan untuk mengembangkan model klasifikasi untuk kanker payudara menggunakan Convolutional Neural Network (CNN) dan mengevaluasi kinerjanya dibandingkan dengan model yang menggunakan transfer learning dengan arsitektur yang telah dilatih sebelumnya. Kedua metode tersebut digunakan untuk memanfaatkan dan memproses data citra histopatologi kanker payudara. Untuk mengevaluasi kinerja model, metrik akurasi dan kehilangan digunakan. Temuan eksperimental menunjukkan bahwa model yang menggunakan transfer learning mencapai akurasi yang lebih baik dan kehilangan yang lebih rendah dibandingkan dengan arsitektur CNN tradisional. Hasilnya menunjukkan bahwa transfer learning dapat meningkatkan efektivitas deteksi dini kanker payudara.

Keywords: Kanker Payudara, Jaringan Syaraf Tiruan Konvolusional, Pembelajaran Transfer, Pembelajaran Mendalam, Klasifikasi Gambar, Deteksi Dini

1. Latar Belakang

Seiring berkembangnya teknologi semakin berkembang juga ilmu pengetahuan baik didalam bidang medis, teknologi, filsafat dan lain-lain. Terutama dalam bidang kesehatan sehingga kita bisa mendeteksi kanker sedari dini dan mencegah kanker tersebut makin mengganas. Kanker payudara merupakan salah satu penyakit mematikan yang paling umum terjadi pada wanita di seluruh dunia. Berdasarkan data dari World Health Organization (WHO, 2021), terdapat sekitar lebih dari 2,3 juta kasus kanker payudara baru yang terdeteksi pada tahun 2020, menjadikannya salah satu kanker yang paling sering menimpa secara umum. Deteksi kanker payudara sejak dini dapat secara signifikan meningkatkan peluang keberhasilan pengobatan dan menurunkan risiko kematian. Seiring dengan kemajuan teknologi, berbagai pendekatan modern, seperti kecerdasan buatan, mulai dimanfaatkan untuk mendukung diagnosis lebih cepat dan akurat.

Dalam beberapa tahun terakhir, perkembangan teknologi kecerdasan buatan (AI) telah memberikan kontribusi yang sangat signifikan didalam bidang kesehatan, terutama dalam hal diagnosis berbasis citra medis. Salah satu teknik yang paling sering digunakan adalah Deep Learning, dengan pendekatan Convolutional Neural Network (CNN) yang terbukti efektif dalam mengenali pola visual yang kompleks. CNN dapat mengekstraksi fitur dari citra medis seperti memmogram atau histopatologi tanpa perlu intervensi manusia secara manual[1].

Namun performa model CNN sangat tergantung pada oleh jumlah kapasitas jumlah data dan kualitas data, data yang tersedia seringkali terbatas karena proses dalam pengumpulan data yang terbilang kompleks serta memakan waktu yang lama. Oleh sebab itu transfer learning hadir sebagai solusi yang digadang-gadang mampu menyelesaikan permasalahan ini. Dengan memanfaatkan model pra-pelatihan seperti VGG-16, ResNet, MobilenetV2, EfficienNet50, dan lainnya, model dapat diadaptasi untuk tugas klasifikasi kanker payudara, meskipun dataset yang terbatas[2].

Penelitian ini bertujuan untuk membandingkan kinerja model CNN yang dilatih dari awal dengan model transfer learning dalam klasifikasi citra kanker payudara. Evaluasi dilakukan berdasarkan metrik akurasi dan loss untuk mengukur efektivitas masing-masing pendekatan model dalam melakukan deteksi kanker secara dini[3].

Meskipun berbagai penelitian telah menerapkan CNN dan transfer learning dalam kasus klasifikasi kanker payudara, perbandingan yang sistematis antara kedua metode tersebut masih sangat diperlukan untuk memahami seutuhnya kelebihan dan kekurangan secara menyeluruh

Dalam melakukan evaluasi mendalam berdasarkan metrik akurasi dan loss, penelitian ini diharapkan dapat memberikan pengetahuan yang bermanfaat dalam pengembangan sistem pendukung keputusan medis yang lebih akurat serta efisien. Selain itu dalam menggunakan transfer learning juga diharapkan dapat meningkatkan efektivitas waktu pelatihan dan kebutuhan data yang besar, sehingga dapat mempercepat implementasi deteksi kanker payudara diberbagai fasilitas kesehatan yang memiliki sumber daya terbatas[4].

Penelitian ini menggunakan dataset citra berbentuk histopatologi kanker payudara yang sudah banyak digunakan dalam penelitian sebelumnya, sehingga hasil yang didapat dapat dibandingkan secara valid dengan penelitian lain di bidang ini[5]. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi yang berarti dalam pengembangan teknologi diagnostik berbasis deep learning yang bisa mendukung upaya deteksi dan pencegahan kanker payudara secara efektif.

Ruang lingkup penelitian ini mencakup preprocessing dataset citra kanker payudara, pembangunan arsitektur CNN, fine-tuning model transfer learning, serta evaluasi performa model menggunakan data validasi dan pengujian[6]. Penelitian ini difokuskan pada klasifikasi gambar menjadi kategori jinak (benign) dan ganas (malignant) sebagai bentuk deteksi dini. Hasil dari penelitian ini diharapkan dapat memberikan wawasan mengenai efektivitas penggunaan deep learning dan transfer learning dalam aplikasi diagnosis kanker berbasis citra medis.

2. Metodologi Penelitian

Penelitian ini menggunakan pendekatan berbasis kuantitatif dengan menerapkan metode eksperimental untuk mendvelop dan membandingkan performa dari ketiga model deep learning dalam klasifikasi citra histopatologi kanker payudara, yaitu model CNN yang dibangun dari awal dan model transfer learning menggunakan arsitektur pra-training[7].

2.1 Dataset

Dataset yang digunakan dalam penelitian ini adalah BreakHis (Breast Cancer Histopathological Database) yang terdiri dari 50.000 gambar, yang terdiri dari dua kelas yaitu:

- Benign (Jinak) – Dilabeli sebagai kelas 0
- Malignant (Ganas) – Dilabeli sebagai kelas 1

Format dan ukuran citra seluruh citra berformat PNG dengan actual size 50x50 dan akan diresize menjadi ukuran 224x224 piksel dengan 3 channel warna, agar sesuai dengan kebutuhan input layer CNN dan model dari transfer learning. Pembagian Dataset dibagi secara beraturan ke dalam tiga bagian yaitu

- Training Set: 70% (35.000 Gambar)
- Test Set: 15% (7.500 Gambar)
- Evaluation Set: 15% (7.500 Gambar)

2.2 Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan sistematis agar dapat membandingkan performa model CNN konvensional dan model transfer learning secara objektif. Tahapan-tahapan tersebut dijelaskan sebagai berikut:

2.2.1. Preprocessing Data

Langkah awal adalah melakukan pra-pemrosesan terhadap dataset citra untuk memastikan kualitas dan keseragaman data yang masuk ke dalam model. Proses ini mencakup:

- Resize: Seluruh citra diubah ukurannya menjadi 224x224 piksel untuk menyesuaikan dimensi input standar dari arsitektur CNN dan model pretrained seperti MobileNetV2, VGG16 dan ResNet50.
- Normalisasi: Nilai piksel dikonversi ke rentang 0–1 dengan membagi setiap piksel dengan 255. Hal ini membantu mempercepat konvergensi model saat pelatihan dan mencegah dominasi nilai besar pada input layer.

- **Augmentasi Data:** teknik augmentasi seperti rotasi, flipping, zooming, dan shifting diterapkan untuk memperluas variasi data pelatihan secara buatan, guna mengurangi risiko overfitting dan meningkatkan generalisasi model.

2.2.2 Pembangunan Arsitektur CNN

Model CNN kustom dibangun dari awal (scratch) untuk melakukan klasifikasi citra kanker payudara. Arsitektur yang digunakan adalah sebagai berikut:

- **Input Layer:** Menyesuaikan dengan ukuran citra hasil resize (224x224 piksel, 3 channel warna).
- **Conv2D:** Beberapa lapisan Conv2D dengan filter 32, 64, dan 128 digunakan untuk mengekstraksi fitur spasial dari citra, masing-masing diikuti dengan aktivasi ReLU dan pooling layer.
- **MaxPooling2D:** Mengurangi dimensi fitur sekaligus mempertahankan fitur penting dengan window 2x2
- **Dropout:** Diterapkan pada beberapa titik (rate 0.3 dan 0.4) untuk mencegah overfitting.
- **Flatten layer:** Mengubah fitur 2D menjadi vektor 1D sebelum masuk ke fully connected layer.
- **Dense Layer:** Layer fully connected dengan 128 neuron dan aktivasi ReLU untuk pemrosesan akhir fitur.
- **Output layer:** Satu neuron dengan fungsi aktivasi sigmoid untuk klasifikasi biner (jinak vs ganas).
- **Optimizer:** Menggunakan Adam optimizer dan *binary crossentropy* sebagai fungsi loss.
- **Training:** Maksimal 100 dengan **EarlyStopping (patience=10)** dan **ModelCheckpoint** berdasarkan akurasi validasi tertinggi.

2.2.3 Transfer Learning dan Fine-Tuning

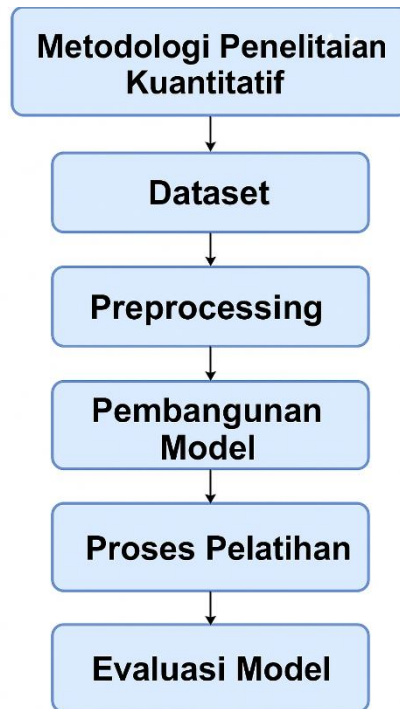
Untuk membandingkan performa dengan pendekatan lain, digunakan tiga arsitektur pretrained yang umum dipakai dalam klasifikasi gambar medis, yaitu

- MobilNetV2
- ResNet50
- VGG16

Setiap arsitektur diuji dalam dua skenario:

- **Tanpa Fine-tuning:** Hanya layer akhir yang diganti dan dilatih, sementara bobot pretrained lainnya dibekukan.
- **Dengan Fine-tuning:** Beberapa layer dari pretrained model dibuka untuk dilatih kembali bersama layer klasifikasi baru, dengan harapan model lebih menyesuaikan diri terhadap karakteristik data histopatologi.

Tujuan utama dari tahapan ini adalah mengevaluasi sejauh mana pretrained model dapat diadaptasi ke domain medis khusus, serta membandingkannya dengan model yang dibangun dan dioptimalkan dari awal.



Gambar 1. Metode Studi Pustaka dengan Pendekatan Kuantitatif

3. Hasil Penelitian dan Pembahasan

Penelitian ini mengimplementasikan dan membandingkan tujuh model klasifikasi citra histopatologi kanker payudara, yang terdiri dari satu model CNN yang dibangun dari awal (custom CNN) dan enam model berbasis transfer learning dengan tiga arsitektur berbeda: MobileNetV2, ResNet50, dan VGG16, masing-masing diterapkan dalam dua skenario: tanpa fine-tuning dan dengan fine-tuning.

3.1 Hasil Eksperimen Model

Kinerja model dievaluasi menggunakan metrik akurasi dan loss pada data uji serta menampilkan training accuracy dan validation accuracy serta training loss dan validation loss. Berikut adalah ringkasan hasil dari ketujuh model tersebut:

Tabel 1.1 Perbandingan Akurasi Model

No	Model	Fine-Tuning	Akurasi (%)	Loss
1	Custom CNN	-	84	0.3973
2	MobileNetV2	Tidak	83	0.3843
3	MobileNetV2	Ya	81	0.5392
4	VGG16	Tidak	80	0.4165
5	VGG16	Ya	82	0.3913
6	ResNet50	Tidak	70	0.5641
7	ResNet50	Ya	52	0.7676

3.2 Pembahasan

Hasil pengujian menunjukkan bahwa pendekatan CNN kustom tanpa pretrained model menunjukkan performa yang stabil dan unggul secara keseluruhan dibandingkan mayoritas model transfer learning yang diuji. Meskipun

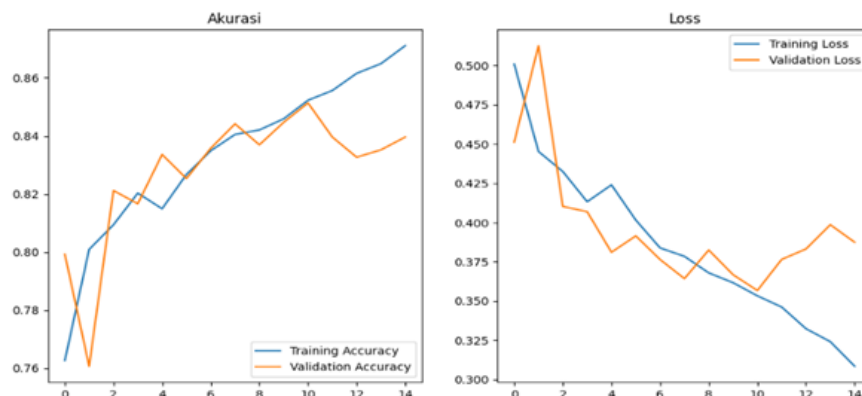
transfer learning umumnya menawarkan keunggulan dalam banyak penelitian, hasil pada eksperimen ini justru mengindikasikan sebaliknya.

Model Custom CNN mencatat akurasi tertinggi sebesar 84% dan loss terendah di antara semua model yang diuji (loss = 0.3973). Ini menunjukkan bahwa ketika data yang digunakan memiliki karakteristik khusus dan domain yang sempit seperti citra histopatologi, model yang dibangun dan dioptimasi dari awal dapat bekerja lebih baik dibanding model pretrained yang lebih umum.

Model MobileNetV2 tanpa fine-tuning menjadi model transfer learning paling mendekati performa Custom CNN, dengan akurasi 83% dan loss 0.3843. Namun, ketika MobileNetV2 dilakukan fine-tuning, performa justru menurun menjadi 81% akurasi dan loss meningkat ke 0.5392, mengindikasikan bahwa proses fine-tuning yang tidak optimal dapat menyebabkan overfitting atau kegagalan model dalam beradaptasi dengan domain baru. (80%) maupun dengan fine-tuning (82%). Ini mengindikasikan bahwa arsitektur VGG relatif tahan terhadap overfitting pada dataset ini. Meski demikian, nilai loss masih lebih tinggi dari model CNN murni.

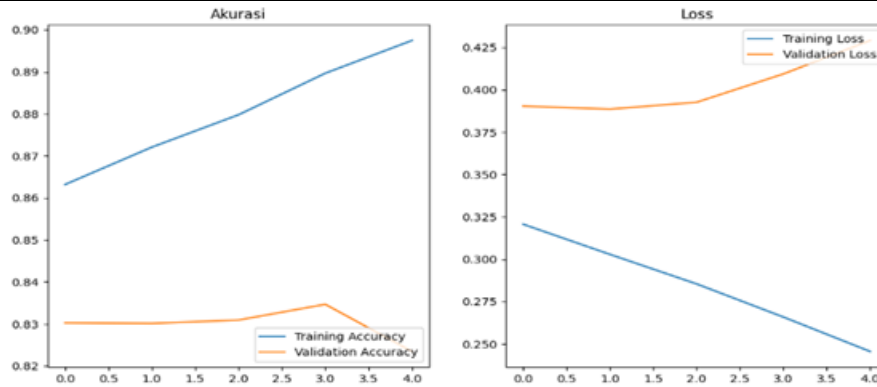
Sebaliknya, hasil pada ResNet50 menunjukkan penurunan performa yang signifikan baik dengan maupun tanpa fine-tuning. Model ResNet50 tanpa fine-tuning mencetak akurasi 70%, sedangkan setelah fine-tuning justru menurun drastis ke 52%, dengan loss tertinggi yaitu 0.7676. Penurunan performa ini kemungkinan besar disebabkan oleh arsitektur ResNet yang sangat dalam, yang tidak cocok diterapkan langsung pada dataset yang relatif terbatas seperti BreakHis tanpa penyesuaian lanjutan. Pada gambar di atas menunjukkan bahwa model mengalami overfit parah, hal ini menyebabkan model tidak bisa menyimpulkan secara jelas pada saat dilakukan testing terhadap data baru

3.3 Visualisasi Metrik Performa Model



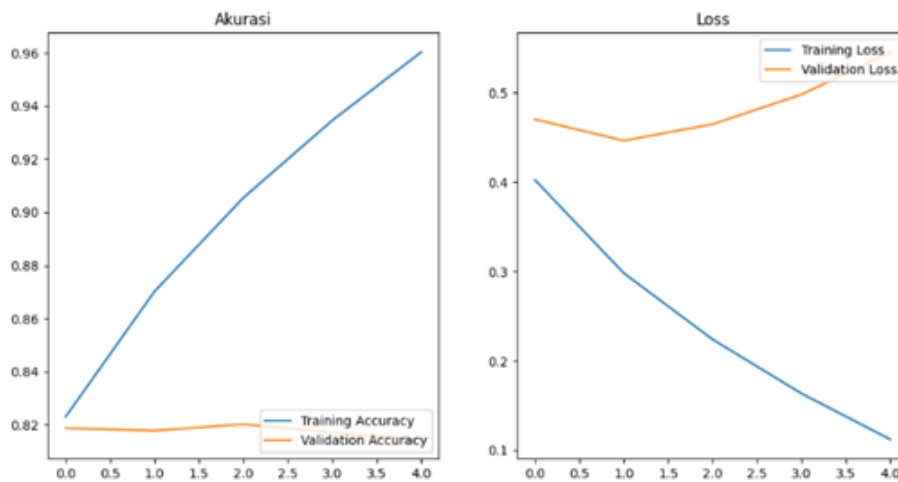
Gambar 2. Metriks Performa dari Model Custom CNN,

Gambar ini menunjukkan grafik akurasi dan loss dari model CNN kustom selama proses pelatihan. Pada awal epoch, baik training accuracy maupun validation accuracy meningkat secara stabil, namun mulai terjadi divergensi setelah epoch ke-10. Validation accuracy mengalami penurunan meski training accuracy terus naik, menandakan awal terjadinya overfitting. Hal yang sama tampak pada grafik loss, di mana validation loss mulai meningkat pada epoch ke-10 sementara training loss terus menurun. Ini menunjukkan bahwa model mulai kehilangan generalisasi pada data baru setelah titik tersebut.



Gambar 3. Metriks Performa dari Model MobileNetV2 tanpa finetuning

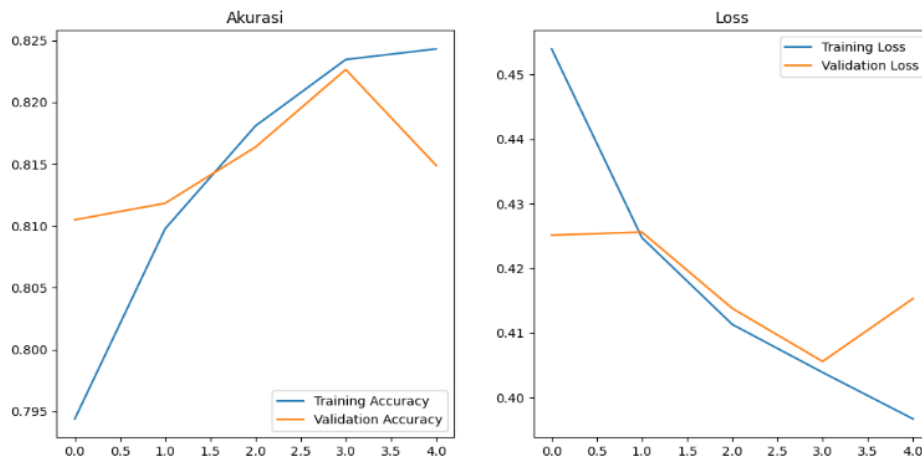
Gambar ini menampilkan performa MobileNetV2 tanpa proses fine-tuning. Terlihat bahwa validation accuracy stagnan di kisaran tertentu, bahkan sempat mengalami fluktuasi. Validation loss juga menunjukkan peningkatan di akhir epoch, mengindikasikan bahwa model mengalami overfitting meskipun arsitektur ini ringan. Hal ini bisa disebabkan oleh perbedaan domain antara data pretraining dan dataset BreakHis, sehingga model sulit menyesuaikan secara optimal tanpa penyesuaian parameter.



Gambar 4. Metriks Performa dari Model MobileNetV2 dengan FineTuning

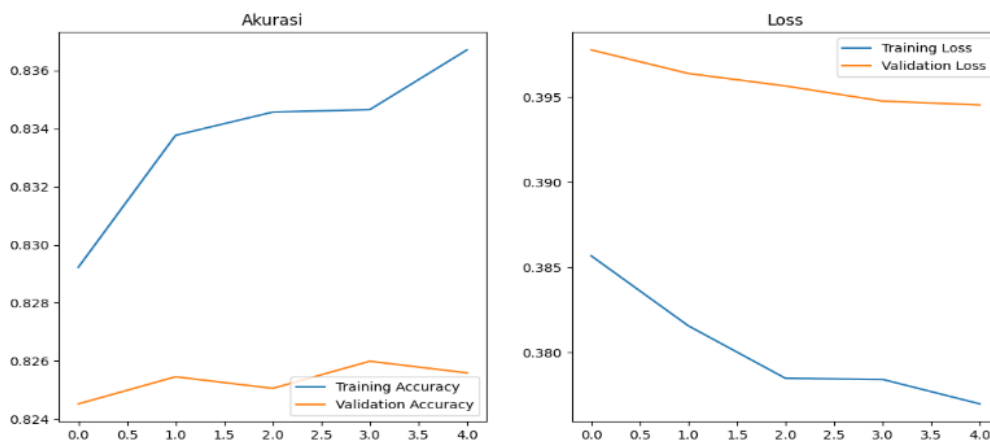
Model MobileNetV2 yang diberi fine-tuning justru menunjukkan indikasi overfitting yang lebih kuat dibandingkan tanpa fine-tuning. Training accuracy sangat tinggi, tetapi validation accuracy rendah dan tidak stabil. Validation loss meningkat tajam di akhir epoch, menunjukkan bahwa model terlalu menyesuaikan diri dengan data

pelatihan dan gagal mengenali pola umum pada data baru. Ini menunjukkan bahwa fine-tuning tanpa pengaturan yang tepat (misalnya learning rate atau layer yang di-unfreeze) dapat merusak kinerja model.




Gambar 5. Metriks Performa dari Model VGG16 Tanpa FineTuning

Grafik performa VGG16 tanpa fine-tuning menunjukkan tren yang lebih stabil dibandingkan MobileNetV2. Tidak terlihat adanya perbedaan ekstrem antara training dan validation accuracy, menunjukkan bahwa model tidak mengalami overfitting berat. Hal ini menandakan bahwa arsitektur VGG16 cukup cocok untuk domain citra histopatologi meskipun tidak dilakukan penyesuaian ulang parameter.




Gambar 6. Metriks Performa dari Model VGG16 dengan FineTuning

Pada versi dengan fine-tuning, model VGG16 mengalami sedikit peningkatan akurasi namun juga menunjukkan gejala overfitting ringan. Validation accuracy mulai menurun setelah beberapa epoch awal, dan validation loss naik. Meski demikian, penurunan performa tidak separah MobileNetV2 dan masih dalam batas wajar. Hal ini menandakan bahwa VGG16 relatif lebih stabil dan adaptif terhadap fine-tuning.



Gambar 7. Metriks Performa dari Model Resnet50 tanpa FineTuning

Meskipun grafik menunjukkan kestabilan antara training dan validation curve, akurasi model tetap rendah dengan loss yang tinggi. Ini menunjukkan bahwa model tidak mampu mengekstraksi fitur secara efektif dari data histopatologi. Kompleksitas ResNet yang dalam tanpa penyesuaian justru membuat proses pembelajaran tidak optimal.



Gambar 8. Metriks Performa dari Model Resnet50 dengan FineTuning

ResNet50 dengan fine-tuning menunjukkan kinerja terburuk. Akurasi training tinggi tetapi validation accuracy sangat rendah dan validation loss sangat tinggi. Ini menunjukkan overfitting parah. Kemungkinan besar, arsitektur yang sangat dalam justru menyulitkan model untuk belajar dari data terbatas tanpa teknik regularisasi atau augmentasi lanjutan yang tepat.

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan mengenai implementasi dan perbandingan model Convolutional Neural Network (CNN) dan Transfer Learning dalam klasifikasi citra histopatologi kanker payudara, dapat disimpulkan beberapa hal sebagai berikut: Model Custom CNN yang dibangun dari awal menunjukkan performa terbaik dengan akurasi tertinggi sebesar 84% dan nilai loss terendah sebesar 0.3973 pada data uji. Hal ini membuktikan bahwa model yang dirancang dan dioptimasi secara khusus untuk dataset yang spesifik seperti citra histopatologi dapat memberikan hasil yang lebih baik dibandingkan model pretrained. Model MobileNetV2 tanpa fine-tuning menjadi alternatif terbaik dari pendekatan transfer learning, dengan akurasi mendekati model Custom CNN, yaitu 83%. Namun, penerapan fine-tuning justru menurunkan performa, yang menunjukkan bahwa proses fine-tuning harus dilakukan secara hati-hati untuk menghindari overfitting. Model VGG16 menunjukkan performa

stabil dengan akurasi 80% (tanpa fine-tuning) dan 82% (dengan fine-tuning). Ini mengindikasikan bahwa arsitektur VGG cukup adaptif terhadap dataset medis, walaupun tetap tidak mengungguli model CNN kustom. Model ResNet50, baik dengan maupun tanpa fine-tuning, menunjukkan performa yang kurang memuaskan. Hasil ini diduga karena kompleksitas arsitektur ResNet yang kurang sesuai untuk dataset yang terbatas seperti BreakHis, sehingga memerlukan penyesuaian arsitektur yang lebih mendalam. Secara umum, pendekatan transfer learning tidak selalu menjamin performa yang lebih baik, terutama jika tidak diikuti dengan fine-tuning yang tepat dan pemahaman terhadap domain data. Model CNN yang dibangun dari awal masih relevan dan dapat bersaing, terutama pada dataset yang spesifik dan terbatas..

Referensi

- [1] A. Holzinger, G. Langs, H. Denk, K. Zatloukal, and H. Müller, "Causability and explainability of artificial intelligence in medicine," Jul. 01, 2019, *Wiley-Blackwell*. doi: 10.1002/widm.1312.
- [2] Shallu and R. Mehra, "Breast cancer histology images classification: Training from scratch or transfer learning?," *ICT Express*, vol. 4, no. 4, pp. 247–254, 2018, doi: <https://doi.org/10.1016/j.ict.2018.10.007>.
- [3] M. T. Ahad, S. Mustofa, F. Ahmed, Y. R. Emon, and A. D. Anu, "A study on Deep Convolutional Neural Networks, Transfer Learning and Ensemble Model for Breast Cancer Detection," Sep. 2024, [Online]. Available: <http://arxiv.org/abs/2409.06699>
- [4] 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, Jan. 2024, doi: 10.1155/2024/5564649.
- [5] H. Hoang Luong, H. Thanh Nguyen, and N. Thai-Nghe, "Detection and classification of breast cancer in mammographic images with fine-tuned convolutional neural networks," *J. Inf. Telecommun.*, vol. 9, no. 2, pp. 209–236, Apr. 2025, doi: 10.1080/24751839.2024.2415033.
- [6] T. Islam, M. E. Hoque, M. Ullah, T. Islam, N. A. Nishu, and R. Islam, "<scp>CNN</scp>-based deep learning approach for classification of invasive ductal and metastasis types of breast carcinoma," *Cancer Med.*, vol. 13, no. 16, Aug. 2024, doi: 10.1002/cam4.70069.
- [7] Z. Cao, L. Duan, G. Yang, T. Yue, and Q. Chen, "An experimental study on breast lesion detection and classification from ultrasound images using deep learning architectures," *BMC Med. Imaging*, vol. 19, no. 1, p. 51, Dec. 2019, doi: 10.1186/s12880-019-0349-x.