

Optimasi Convolutional Neural Networks untuk Deteksi Kanker Payudara menggunakan Arsitektur DenseNet

Ryan Ali Mas'ud^{1,*}, Junta Zeniarja¹

¹ Program Teknik Informatika, Universitas Dian Nuswantoro, Indonesia

* Correspondence: 111202012531@mhs.dinus.ac.id

Copyright: © 2024 by the authors

Received: 3 Mei 2024 | Revised: 6 Mei 2024 | Accepted: 22 Mei 2024 | Published: 20 Juni 2024

Abstrak

Kanker payudara adalah penyakit yang umumnya diderita oleh perempuan di seluruh dunia, menempati peringkat kedua sebagai penyakit terbesar. Dalam menghadapi kebutuhan mendesak untuk optimasi akurasi deteksi, Convolutional Neural Network menjanjikan kemajuan signifikan. Tujuan penelitian ini adalah untuk mengoptimalkan penggunaan CNN dengan arsitektur DenseNet dalam mendeteksi kanker payudara. Metode penelitian ini menggunakan metode kuantitatif dengan Deep Learning melalui CNN. Data mammografi diperoleh dari sumber Kaggle dengan nama "Breast Histopathology Images". Data tersebut terdiri dari 90,000 citra digital hasil mammografi, yang diproses dan dipisahkan secara proporsional untuk pelatihan, validasi, dan pengujian model. Variabel penelitian meliputi parameter dataset gambar citra digital, teknik-teknik pelatihan yang digunakan, serta integrasi modalitas pencitraan untuk meningkatkan kinerja deteksi kanker payudara. Subjek penelitian ini adalah data mamografi yang diolah, sementara objek penelitian meliputi akurasi dan kualitas citra dalam pengambilan sampel kanker payudara. Hasil temuan kami menunjukkan bahwa arsitektur DenseNet dalam CNN berhasil mencapai akurasi sebesar 92% dalam mendeteksi kanker payudara. Performa yang luar biasa ini menandakan kesuksesan dalam meningkatkan kualitas citra dan prediksi kelas sesuai dengan alur diagram arsitektur DenseNet. Hasil ini juga dapat memberikan kontribusi signifikan dalam mendiagnosis kanker payudara secara efektif, dengan mengoptimalkan penggunaan CNN dengan arsitektur DenseNet untuk meningkatkan kualitas citra dalam pengambilan sampel kanker payudara.

Kata kunci: convolutional neural networks (cnn); deteksi kanker payudara; deep learning; densenet

Abstract

Breast cancer is a disease commonly suffered by women worldwide, ranking as the second-largest disease burden. In response to the urgent need for improved detection accuracy, Convolutional Neural Networks (CNNs) promise significant advancements. The objective of this research is to optimize the use of CNNs with the DenseNet architecture for breast cancer detection. The study employs quantitative methods, leveraging Deep Learning through CNNs. Mammography data is sourced from Kaggle, specifically the "Breast Histopathology Images" dataset. This dataset comprises 90,000 digital mammography images, which are preprocessed and divided proportionally for training, validation, and model testing. Research variables encompass CNN model parameters, training techniques, and the integration of imaging modalities to enhance breast cancer detection performance. The research focuses on processed mammography data, with accuracy and image quality as key evaluation metrics for breast cancer sample identification. Our findings demonstrate that the DenseNet architecture within CNNs achieves an impressive 92% accuracy in breast cancer detection. This remarkable performance signifies success in enhancing image quality and class prediction, aligning with the DenseNet architecture's flow diagram. Ultimately, these results contribute significantly to effective breast cancer diagnosis by optimizing CNNs with the DenseNet architecture to improve image quality during breast cancer sampling.



Keywords: *convolutional neural networks (cnn); breast cancer detection; deep learning; densenet*

PENDAHULUAN

Kanker payudara adalah jenis kanker yang sering terjadi pada perempuan; dimulai di jaringan payudara dan kemudian dapat menyebar ke bagian tubuh lainnya (Jabeen et al., 2022). Secara umum, kanker payudara mengacu pada pertumbuhan jaringan payudara yang tidak teratur dan tidak normal, yang kemudian berkembang menjadi struktur yang menyerupai tumor (Khan et al., 2022). Semakin awal stadium kanker payudara, semakin baik peluang untuk bertahan hidup. Kanker payudara yang terdeteksi pada stadium sangat awal umumnya memiliki peluang penyembuhan sebesar 90%, tetapi jika kanker menyebar ke kelenjar getah bening atau bagian tubuh lainnya, peluang penyembuhan secara signifikan menurun. Peluang bertahan hidup menurun secara signifikan setelah deteksi tumor ganas (Balasubramaniam et al., 2023). Oleh karena itu, identifikasi penyakit pada fase awal sangat penting dalam menyelamatkan nyawa dengan memberikan perawatan yang tepat waktu. Mamografi dan USG adalah dua teknik skrining kanker payudara yang populer dan terjangkau (Sahu et al., 2023).

Kanker payudara merupakan penyebab utama kematian di kalangan perempuan. Data dari Globocan tahun 2020 menunjukkan bahwa kanker payudara menempati urutan pertama terkait jumlah kanker terbanyak di Indonesia. Jumlah kasus baru kanker payudara mencapai 68.858 kasus (16,6%) dari total 396.914 kasus baru kanker di Indonesia (Rizaty, 2021). WHO juga mencatat bahwa kanker payudara adalah kejadian kanker tertinggi di Indonesia, yakni sebesar 16,7%, dan tingkat kematian tertinggi kedua setelah kanker paru-paru, yakni sebesar 11% (Dewi, 2023). Mengingat urgensi untuk meningkatkan deteksi dini dan akurasi diagnosis, upaya untuk mengoptimalkan teknologi deteksi kanker payudara menjadi sangat penting (Roslidar et al., 2020). Solusi untuk meningkatkan akurasi dalam mendeteksi kanker payudara adalah dengan memanfaatkan Convolutional Neural Networks (CNN) yang menjanjikan kemajuan signifikan dalam bidang ini (Wang, 2022). Dalam konteks ini, arsitektur DenseNet menjadi pilihan yang menarik karena potensinya untuk mengoptimalkan kinerja model. Dengan mempertahankan informasi lebih banyak melalui koneksi yang lebih dekat antara lapisan-lapisan, DenseNet dapat mengatasi masalah vanishing gradient dan meningkatkan aliran informasi di dalam jaringan (Ramdhana & Pratiwi, 2023). Citra digital memungkinkan representasi yang lebih akurat dari detail-detail kecil pada gambar, yang merupakan tantangan utama dalam deteksi massa payudara dengan ukuran yang sangat kecil pada gambar mamografi (Jabeen et al., 2022). Teknologi citra digital juga memungkinkan peningkatan kontras untuk massa payudara yang memiliki kontras rendah, sehingga meningkatkan kemampuan untuk mendeteksi lesi yang mungkin terlewatkan pada mammogram resolusi tinggi (Ibrokhimov & Kang, 2022).


Metode CNN adalah pendekatan yang kuat dalam pengenalan pola pada data citra (Albakia & Saputra, 2023; Zhang et al., 2023). CNN dapat secara otomatis mengekstraksi fitur-fitur penting dari gambar, termasuk fitur-fitur yang mungkin sulit diidentifikasi oleh manusia (Qotrunnada & Utomo, 2022). Meskipun banyak penelitian telah menunjukkan keberhasilan penggunaan CNN dalam deteksi kanker payudara, terdapat beberapa area kritis yang memerlukan penelitian lebih lanjut (Mohamed et al., 2023). Model yang ada seringkali memiliki kompleksitas tinggi, menyebabkan waktu komputasi yang panjang dan kebutuhan sumber daya yang besar (Zhu et al., 2023), sehingga diperlukan pengembangan model yang lebih efisien tanpa mengorbankan akurasi. Selain itu, masalah overfitting sering muncul akibat ukuran dataset yang terbatas dan kurangnya data berlabel berkualitas tinggi, sehingga teknik regularisasi dan augmentasi data perlu dioptimalkan (Trang et al., 2023). Proses tuning hyperparameter yang optimal juga masih menjadi tantangan besar, seringkali membutuhkan pendekatan trial-and-error yang memakan waktu dan sumber daya (Jafari & Karami, 2023). Lebih jauh lagi, banyak model belum diuji secara luas pada berbagai dataset, sehingga

kemampuan generalisasi mereka terhadap data baru masih diragukan (Sahu et al., 2023). Celah ini dapat dimanfaatkan oleh penelitian kami untuk menjawab pertanyaan apakah model CNN dengan arsitektur DenseNet dapat dimaksimalkan dengan metode yang dianggap berhasil dalam memproses dan melatih data supaya akurasi yang dihasilkan tinggi.

Berdasarkan hal tersebut, penelitian ini mengisi kesenjangan dalam masalah tersebut dengan mengusulkan pendekatan yang lebih canggih menggunakan teknologi citra digital dan metode CNN untuk meningkatkan deteksi massa payudara pada mammografi resolusi tinggi dan menggunakan dataset yang relatif lebih besar, dengan 90.000 gambar citra digital. Penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam pengembangan teknik deteksi yang lebih canggih dan andal. Tujuan penelitian ini adalah untuk mengoptimasi metode yang dapat meningkatkan deteksi massa payudara pada gambar mammografi resolusi tinggi dengan memanfaatkan teknologi citra digital dan metode Convolutional Neural Networks (CNN), sehingga dapat memberikan hasil yang lebih akurat dan dapat diandalkan untuk skrining kanker payudara.

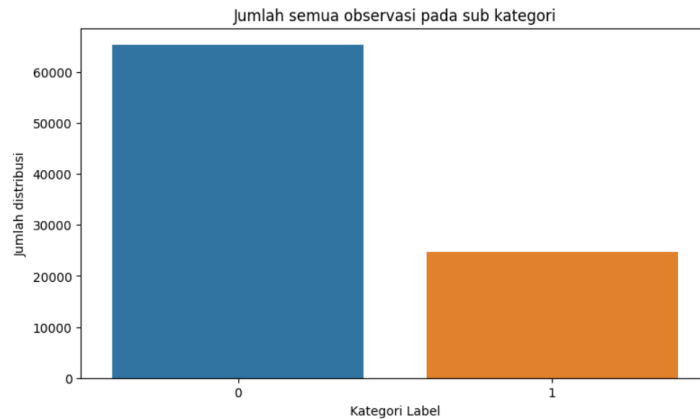
METODE

Pada alur CNN gambar 1, langkah awal adalah memasukkan data input, seperti gambar mamografi, ke dalam jaringan. Selanjutnya, fitur-fitur penting diekstraksi melalui lapisan konvolusi dan pooling untuk mendeteksi pola visual yang relevan. Setelah proses ekstraksi fitur, fitur-fitur tersebut diubah menjadi vektor satu dimensi melalui flatten layer. Kemudian, vektor fitur melewati lapisan-lapisan dense yang terdiri dari neuron-neuron terhubung sepenuhnya, di mana fitur-fitur digabungkan menjadi representasi abstrak (Diwakaran & Surendran, 2023). Lapisan output menghasilkan prediksi kelas, seperti "normal" atau "abnormal" dalam deteksi kanker payudara, dengan neuron-neuron menghasilkan probabilitas untuk setiap kelas. Penelitian ini menggunakan CNN, khususnya DenseNet, untuk deteksi kanker payudara dengan data mamografi dari Breast Histopathology Images di Kaggle. Dataset dipilih untuk mencakup berbagai kondisi payudara dan variasi seperti kepadatan jaringan dan ukuran tumor. Data dipisahkan secara proporsional untuk memastikan generalisasi yang baik, yaitu setiap subset data mencakup proporsi representatif dari gambar normal dan yang menunjukkan kanker payudara, serta variasi lainnya.



Gambar 1. Ilustrasi alur diagram *convolutional neural network*

Pada gambar 2 dijelaskan bahwa dataset tersebut terdiri dari gambar-gambar yang telah diberi label untuk mengindikasikan apakah gambar tersebut menunjukkan keberadaan kanker payudara atau tidak. Label 1 menunjukkan bahwa gambar tersebut terindikasi mengandung kanker payudara, sementara label 0 menunjukkan bahwa gambar tersebut tidak menunjukkan keberadaan kanker payudara. Jumlah 65.318 gambar dengan label 0 menunjukkan bahwa mayoritas gambar dalam dataset tersebut mungkin tidak menunjukkan keberadaan kanker payudara, sementara jumlah 24.682 gambar dengan label 1 menunjukkan bahwa sejumlah gambar dalam dataset tersebut menunjukkan indikasi kanker payudara.



Gambar 2. Distribusi data label pada dataset

Konvolusi dalam CNN adalah operasi matematis yang mengekstraksi fitur-fitur penting dari data berdimensi tinggi, seperti citra (Alsalihi et al., 2022). Dengan menggunakan filter atau kernel yang bergerak di atas citra input, konvolusi memungkinkan CNN mendeteksi pola-pola seperti tepi, tekstur, atau fitur-fitur kompleks. Stride mengatur pergeseran filter, sementara padding menjaga ukuran citra. Hasilnya adalah feature map, merepresentasikan distribusi fitur-fitur. Dengan konvolusi, CNN memahami struktur spasial data, menghasilkan representasi untuk klasifikasi, deteksi objek, dan segmentasi. Arsitektur CNN terdiri dari beberapa jenis lapisan yang masing-masing memiliki peran penting dalam pemrosesan dan klasifikasi data gambar. Lapisan konvolusi (*Convolutional Layer*) menerapkan filter (kernel) pada input gambar untuk mengekstrak fitur-fitur penting seperti tepi atau tekstur. Proses ini bisa dijelaskan pada persamaan 1.

$$Output = Convolution(Input, Filter) + Bias \quad (1)$$


Konvolusi antara input dan filter ditambah bias menghasilkan output fitur. Lapisan *pooling* (*Pooling Layer*) berfungsi untuk mereduksi dimensi spasial dari fitur yang dihasilkan oleh lapisan konvolusi, sehingga mengurangi jumlah parameter yang harus dipelajari dan mempercepat proses komputasi. Teknik umum yang digunakan adalah max pooling, yang memilih nilai maksimum dari bagian kecil dari peta fitur (feature map) tertentu. Setelah beberapa lapisan konvolusi dan pooling, fitur-fitur ini disalurkan ke dalam lapisan fully connected (Dense Layer), yang setiap neuronnya terhubung dengan setiap neuron di lapisan sebelumnya. Aktivasi dari lapisan ini dihitung menggunakan persamaan 2.

$$Output = Activation(Input \times Weights + Bias) \quad (2)$$

Input yang dikalikan dengan bobot dan ditambah bias dilewatkan melalui fungsi aktivasi untuk menghasilkan output akhir. Lapisan *dropout* (*Dropout Layer*) sering digunakan sebagai teknik regularisasi untuk mencegah overfitting, dengan menonaktifkan secara acak sebagian neuron selama proses pelatihan, sehingga jaringan tidak terlalu bergantung pada neuron tertentu dan menjadi lebih robust.

Densenet121 pada gambar 3 adalah model CNN yang efektif dalam deteksi kanker payudara berkat strukturnya yang inovatif. Konektivitas antar-layer yang kuat memahami fitur-fitur hierarkis kompleks dalam citra, krusial dalam deteksi kanker payudara. Dengan penggabungan fitur di semua lapisan, model ini memfasilitasi aliran informasi yang efisien dan pembelajaran yang dalam, mendukung pengambilan keputusan yang akurat. Ini tidak hanya menghasilkan akurasi tinggi dalam pengenalan pola patologis tetapi juga memperkuat

interpretasi klinis dan meningkatkan efisiensi diagnosa. Teknik augmentasi data diterapkan untuk keragaman data pelatihan, dengan pelatihan menggunakan data mamografi dan mempercepat proses dengan GPU (Alshehri & ALSaeed, 2022).




Gambar 3. Ilustrasi alur diagram arsitektur *densenet121*

HASIL DAN PEMBAHASAN

Hasil

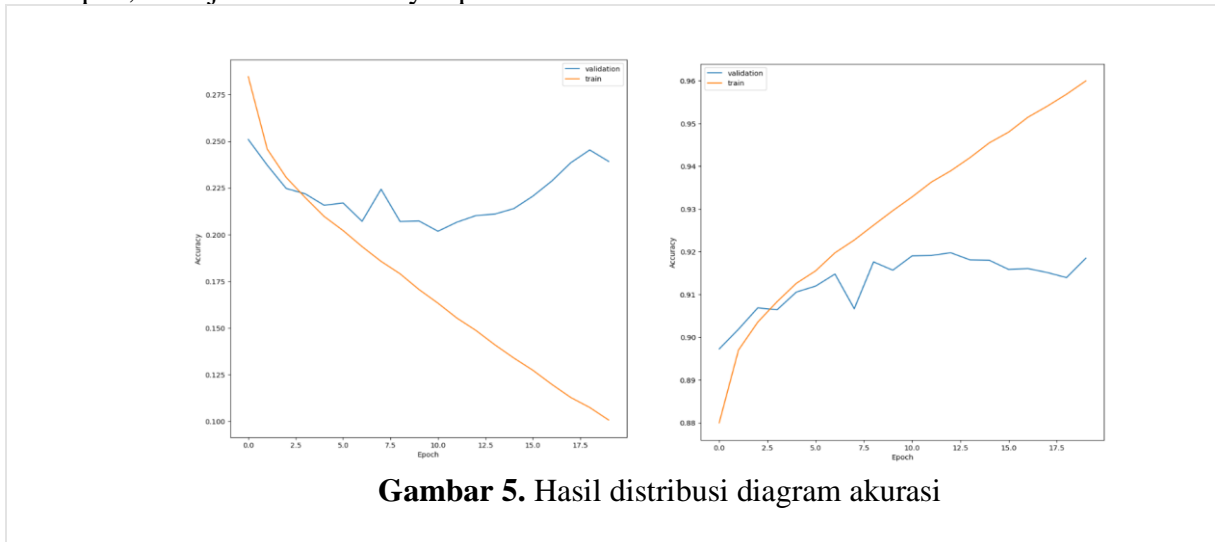
Hasil pada gambar 4 menunjukkan sebuah keberagaman jenis data yang ada dalam dataset, meliputi data gambar yang terindikasi kanker dan yang tidak terindikasi kanker. Dengan infrastruktur dataset pada gambar 4 dan label dataset pada gambar 2, pengembangan model menjadi lebih terstruktur, efisien, dan mudah diatur. Dengan menggunakan pendekatan yang telah dijelaskan sebelumnya. DataFrame `images_df` dibuat untuk menyimpan gambar-gambar yang telah diproses beserta label-label yang ada pada gambar 4, menjadi langkah kunci dalam persiapan data untuk proses pelatihan dan evaluasi model. Dataset dibagi menjadi subset data pelatihan, validasi, dan pengujian menggunakan fungsi `train_test_split`, memastikan distribusi yang seimbang dari kelas-kelas yang ada di setiap subset data. Dengan pembagian ini, kita dapat melanjutkan ke tahap pelatihan model dengan dataset yang telah dipisahkan secara tepat.



Gambar 4. Gambar data acak dalam dataset

Pengaturan parameter-parameter pelatihan seperti jumlah epoch, jumlah kelas, ukuran batch, dan tingkat pembelajaran yang telah ditentukan, memungkinkan kita untuk melakukan proses pelatihan model klasifikasi. Dengan nilai-nilai tersebut, kita memiliki kerangka kerja yang telah disiapkan dengan baik untuk melatih model dengan dataset yang telah dipisahkan sebelumnya, seperti pada gambar 2 dimana terdapat 2 label yaitu 1 untuk gambar positif terkena indikasi kanker dan 0 untuk gambar yang tidak terindikasi kanker.

Model DenseNet disesuaikan dengan menambahkan lapisan linear baru pada classifier, yang dilengkapi dengan fungsi aktivasi sigmoid untuk menghasilkan probabilitas kelas. Data dimuat menggunakan DataLoader dalam batch sesuai dengan ukuran yang ditentukan. Selama pelatihan, menggunakan loss binary cross-entropy untuk mengukur kesesuaian prediksi dengan label yang sebenarnya, dan optimizer Adam untuk mengoptimalkan parameter. Setelah iterasi sebanyak jumlah epoch yang ditentukan, model dievaluasi menggunakan data pelatihan dan validasi, menghitung loss dan akurasi dari setiap batch pelatihan, serta akumulasi loss dan akurasi pada data validasi. Jika akurasi pada validasi lebih baik dari sebelumnya, bobot model disimpan, bertujuan untuk menyimpan model terbaik.



Gambar 5. Hasil distribusi diagram akurasi

Diagram akurasi yang diperlihatkan pada gambar 5 menunjukkan perkembangan akurasi model pada setiap epoch selama proses pelatihan. Awalnya, akurasi pada data pelatihan dan validasi meningkat seiring berjalannya epoch, menandakan bahwa model secara bertahap mempelajari pola-pola yang ada dalam data. Hal ini tercermin dari konsistensi peningkatan akurasi pada kedua dataset, yang menyiratkan bahwa model berhasil menangkap pola-pola yang relevan dalam data pelatihan. Meskipun terjadi fluktuasi kecil dalam akurasi pada beberapa epoch terakhir, akurasi akhir model pada data pengujian tetap tinggi, menunjukkan bahwa model mampu melakukan prediksi dengan konsisten.

Accuracy of the model on the validation images: 91.68363210521575 %

Gambar 6. Hasil akurasi validasi

Pada hasil yang diperoleh sesuai dalam gambar 6, akurasi model pada gambar validasi mencapai 91.68%, menunjukkan performa yang baik. Hasil evaluasi ini memberikan gambaran tentang kemampuan model dalam memvalidasi keandalan dan konsistensi model dalam melakukan tugas klasifikasi pada dataset yang digunakan. Untuk evaluasi performa model kita menggunakan metrik-metrik klasifikasi seperti *confusion matrix* dan *classification report*. *Confusion matrix* memberikan gambaran tentang jumlah prediksi yang benar dan salah untuk setiap kelas, sementara *classification report* memberikan detail tentang metrik evaluasi seperti presisi, recall, dan F1-score untuk setiap kelas. Evaluasi ini memberikan pemahaman yang lebih dalam tentang performa model dalam melakukan klasifikasi pada data pengujian, serta membantu dalam mengidentifikasi area di mana model dapat ditingkatkan untuk meningkatkan kinerja secara keseluruhan.

Tabel 1. Hasil *confusion matrix*

	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	<i>Support</i>
0	0,94	0,95	0,94	39748
1	0,87	0,83	0,85	15757
Accuracy			0,92	55505
Macro avg	0,90	0,89	0,90	55505
Weighted avg	0,92	0,92	0,92	55505

Hasil evaluasi pada tabel 1 menunjukkan bahwa model memiliki performa yang sangat baik dalam mengidentifikasi gambar yang tidak terindikasi kanker payudara (kelas 0), namun sedikit lebih rendah dalam mengidentifikasi gambar yang terindikasi kanker payudara (kelas 1) memiliki implikasi yang penting dalam konteks kanker payudara. Keberhasilan model dalam mengidentifikasi gambar yang tidak terindikasi kanker payudara (kelas 0) dengan *Precision*, *Recall*, dan *F1-score* yang sangat tinggi (masing-masing 0,94, 0,95, dan 0,94) menunjukkan bahwa model mampu secara efektif membedakan gambar-gambar normal dari yang menunjukkan adanya kanker payudara. Hal ini penting karena membantu meminimalkan jumlah kesalahan diagnosis palsu negatif, di mana gambar yang sebenarnya menunjukkan tanda-tanda kanker tidak terdeteksi. Namun, adanya performa yang sedikit lebih rendah dalam mengidentifikasi gambar yang terindikasi kanker payudara (kelas 1), terutama dalam *Recall* (0,83) dan *F1-score* (0,85), menyoroti tantangan yang masih ada dalam deteksi kanker payudara menggunakan model ini. *Recall* yang rendah berarti ada kemungkinan model mengabaikan beberapa gambar yang sebenarnya menunjukkan tanda-tanda kanker payudara. Hal ini dapat menyebabkan kesalahan diagnosis palsu positif, di mana pasien dengan kanker sebenarnya dianggap tidak memiliki kanker.

Pembahasan

Pada penelitian kami, kami melakukan evaluasi terhadap model DenseNet dalam deteksi kanker payudara. Hasil evaluasi menunjukkan akurasi sebesar 92% pada data validasi, yang menunjukkan performa yang luar biasa. Akurasi ini dihasilkan melalui beberapa tahapan penelitian yang kami lakukan. Dalam mendeteksi kanker payudara, hal penting yang dilihat dari hasil temuan kami adalah akurasi dalam memprediksi keberadaan atau tidaknya tumor payudara. Akurasi sebesar 92% ini mengindikasikan bahwa model kami mampu dengan baik dalam mengklasifikasikan citra-citra sebagai kanker payudara atau bukan. Dikarenakan CNN secara efisien mengekstraksi fitur-fitur berhierarki dari citra, sementara DenseNet memungkinkan pemanfaatan informasi global dan lokal secara simultan melalui koneksi dense antara lapisan. Keunggulan ini sangat penting dalam konteks medis, karena deteksi dini kanker payudara dapat meningkatkan peluang kesembuhan pasien dan memungkinkan intervensi yang lebih cepat dan tepat.

Model DenseNet kami juga menunjukkan ketahanan yang baik terhadap variasi dalam data, seperti perbedaan dalam kualitas gambar dan variasi anatomi individu, yang sering menjadi tantangan dalam analisis citra medis. Selain itu, penggunaan DenseNet mengurangi risiko kehilangan informasi penting karena setiap lapisan menerima input langsung dari semua lapisan sebelumnya, memastikan bahwa detail-detail kecil yang mungkin menunjukkan keberadaan tumor tidak terlewatkan. Dalam aspek lain, kekurangan dari model yang kami buat adalah ketidakseimbangan antar dataset label 1 dengan label 0. Dimana label 1 memiliki akurasi yang kurang dari label 0. Dengan perbedaan jumlah data label yang cukup signifikan, untuk penelitian kedepannya diperlukan adanya perbaikan dalam teknik augmentasi yang digunakan sehingga akurasi pada label 1 dapat meningkat.

Penelitian lain yang relevan menggunakan berbagai algoritma pembelajaran mesin seperti kNN, SVM, RF, dan NN (Jafari & Karami, 2023) dan menggunakan tiga model

Attention Mechanism (AM) dengan CNN untuk diagnosis kanker payudara menggunakan gambar termografi (Alshehri & AlSaeed, 2022) memiliki keterbatasan ketersediaan dataset gambar termal payudara dan ukuran dataset yang relatif kecil. Dalam perbandingan dengan jumlah data tersebut kami menemukan bahwa penggunaan DenseNet pada penelitian yang kami lakukan memberikan hasil yang signifikan. Hal ini mungkin disebabkan oleh keunggulan DenseNet dalam memahami hubungan yang kompleks antara fitur-fitur dalam citra dan kemampuannya untuk memanfaatkan informasi yang tersedia secara efisien. Selain itu, integrasi berbagai modalitas pencitraan juga dapat menjadi faktor penentu dalam peningkatan performa model. Hasil temuan kami menunjukkan bahwa penggunaan model DenseNet dalam deteksi kanker payudara memberikan hasil yang memuaskan dengan akurasi sebesar 92%. Pendekatan yang kami ambil dalam processing data sangat berperan penting dalam mencapai akurasi tinggi. Dalam tahap *preprocessing*, kami menggunakan teknik augmentasi data untuk mengolah dataset agar tidak terjadi *overfitting*, meningkatkan generalisasi data, dan menyelesaikan masalah ketidakseimbangan kelas-kelas label pada *dataset*.

SIMPULAN

Penelitian kami menunjukkan bahwa penggunaan model DenseNet dalam deteksi kanker payudara pada tahap awal dapat meningkatkan prognosis pasien dan mengurangi angka mortalitas terkait penyakit ini. Ini berpotensi memicu pengembangan teknologi deteksi yang lebih canggih di masa depan, membawa dampak positif bagi bidang kedokteran, ilmu komputer, dan praktik klinis. Dengan kemampuan deteksi yang mencapai 92%, diharapkan akan memberi manfaat diagnosis dini dan intervensi yang tepat waktu, menghasilkan dampak positif pada prognosis pasien dan mengurangi dampak negatif penyakit kanker payudara. Temuan ini juga berpotensi menjadi landasan bagi pengembangan produk dan layanan yang lebih efektif dalam deteksi dan penanganan kanker payudara oleh instansi terkait seperti lembaga kesehatan, penelitian medis, dan industri teknologi kesehatan.

REFERENSI

- Albakia, S. A. E., & Saputra, R. A. (2023). Identifikasi Jenis Daun Tanaman Obat Menggunakan Metode Convolutional Neural Network (CNN) Dengan Model VGG16. *Jurnal Informatika Polinema*, 9(4), 451-460. <https://doi.org/10.33795/jip.v9i4.1420>
- Alsalihi, A., K. Aljobouri, H. ., & ALTameemi, E. A. K. (2022). GLCM and CNN Deep Learning Model for Improved MRI Breast Tumors Detection. *International Journal of Online and Biomedical Engineering (iJOE)*, 18(12), 123–137. <https://doi.org/10.3991/ijoe.v18i12.31897>
- Alshehri, A., & AlSaeed, D. (2022). Breast Cancer Detection in Thermography Using Convolutional Neural Networks (CNNs) with Deep Attention Mechanisms. *Applied Sciences*, 12(24), 1-19. <https://doi.org/10.3390/app122412922>
- Balasubramaniam, S., Velmurugan, Y., Jaganathan, D., & Dhanasekaran, S. (2023). A modified LeNet CNN for breast cancer diagnosis in ultrasound images. *Diagnostics*, 13(17), 1-28. <https://doi.org/10.3390/diagnostics13172746>
- Diwakaran, M., & Surendran, D. (2023). Breast Cancer Prognosis Based on Transfer Learning Techniques in Deep Neural Networks. *Information Technology and Control*, 52(2), 381-396. <https://doi.org/10.5755/j01.itc.52.2.33208>
- Dewi, A. P. (2023). *DJSN sebut kanker penyakit biaya tertinggi kedua setelah jantung*. Antara News. Retrieved May 2, 2024, from [DJSN sebut kanker penyakit biaya tertinggi kedua setelah jantung - ANTARA News](https://www.antaranews.com/berita/1234567890/djsn-sebut-kanker-penyakit-biaya-tertinggi-kedua-setelah-jantung)

- Ibrokhimov, B., & Kang, J. Y. (2022). Two-stage deep learning method for breast cancer detection using high-resolution mammogram images. *Applied Sciences*, *12*(9), 1-14. <https://doi.org/10.3390/app12094616>
- Jabeen, K., Khan, M. A., Alhaisoni, M., Tariq, U., Zhang, Y. D., Hamza, A., ... & Damaševičius, R. (2022). Breast cancer classification from ultrasound images using probability-based optimal deep learning feature fusion. *Sensors*, *22*(3), 1-23. <https://doi.org/10.3390/s22030807>
- Jafari, Z., & Karami, E. (2023). Breast cancer detection in mammography images: A CNN-based approach with feature selection. *Information*, *14*(7), 1-14. <https://doi.org/10.3390/info14070410>
- Khan, M. M., Tazin, T., Zunaid Hussain, M., Mostakim, M., Rehman, T., Singh, S., Gupta, V., & Alomeir, O. (2022). Breast Tumor Detection Using Robust and Efficient Machine Learning and Convolutional Neural Network Approaches. *Computational Intelligence and Neuroscience*, *2022*, 1-11. <https://doi.org/10.1155/2022/6333573>
- Mohamed, T. I., Ezugwu, A. E., Fonou-Dombeu, J. V., Ikotun, A. M., & Mohammed, M. (2023). A bio-inspired convolution neural network architecture for automatic breast cancer detection and classification using rna-seq gene expression data. *Scientific Reports*, *13*(1), 14644. <https://doi.org/10.1155/2022/6333573>
- Qotrunnada, F. M., & Utomo, P. H. (2022). Metode Convolutional Neural Network untuk Klasifikasi Wajah Bermasker. *Prisma*, *5*, 799-807.
- Ramdhana, A. C., & Pratiwi, N. (2023). Perbandingan Kinerja Model Convolutional Neural Network pada Klasifikasi Kanker Kulit. *Edumatic: Jurnal Pendidikan Informatika*, *7*(2), 197-206. <https://doi.org/10.29408/edumatic.v7i2.19823>
- Rizaty, M. A. (2021). Ini Jenis Kanker yang Paling Banyak Diderita Penduduk Indonesia. Retrieved May 16, 2024, from Databoks website: <https://databoks.katadata.co.id/datapublish/2021/06/29/ini-jenis-kanker-yang-paling-banyak-diderita-penduduk-indonesia>
- Roslidar, R., Rahman, A., Muharrar, R., Syahputra, M. R., Arnia, F., Syukri, M., ... & Munadi, K. (2020). A review on recent progress in thermal imaging and deep learning approaches for breast cancer detection. *IEEE access*, *8*, 116176-116194. <https://doi.org/10.1109/ACCESS.2020.3004056>
- Sahu, A., Das, P. K., & Meher, S. (2023). High accuracy hybrid CNN classifiers for breast cancer detection using mammogram and ultrasound datasets. *Biomedical Signal Processing and Control*, *80*, 104292. <https://doi.org/10.1016/j.bspc.2022.104292>
- Trang, N. T. H., Long, K. Q., An, P. L., & Dang, T. N. (2023). Development of an artificial intelligence-based breast cancer detection model by combining mammograms and medical health records. *Diagnostics*, *13*(3), 1-18. <https://doi.org/10.3390/diagnostics13030346>
- Wang, L. (2022). Holographic Microwave Image Classification Using a Convolutional Neural Network. *Micromachines*, *13*(12), 1-19. <https://doi.org/10.3390/mi13122049>
- Zhang, Y., Liu, Y. L., Nie, K., Zhou, J., Chen, Z., Chen, J. H., ... & Su, M. Y. (2023). Deep learning-based automatic diagnosis of breast cancer on MRI using mask R-CNN for detection followed by ResNet50 for classification. *Academic radiology*, *30*, S161-S171. <https://doi.org/10.1016/j.acra.2022.12.038>
- Zhu, Z., Wang, S. H., & Zhang, Y. D. (2023). A survey of convolutional neural network in breast cancer. *Computer modeling in engineering & sciences: CMES*, *136*(3), 2127-2172. <https://doi.org/10.32604/cmes.2023.025484>