

Klasifikasi Kanker Payudara Berdasarkan Gambar Histopatologi Menggunakan Metode Convolutional Neural Network Dengan Arsitektur VGG-16

Dayang Nandasari*, Irfan Pratama

Fakultas Teknologi Informasi, Program Studi Sistem Informasi, Universitas Mercu Buana Yogyakarta, Yogyakarta, Indonesia

Email: ^{1,*}211210032@student.mercubuana-yogya.ac.id, ²Irfanp@mercubuana-yogya.ac.id

Email Penulis Korespondensi: ¹211210032@student.mercubuana-yogya.ac.id

Submitted: 17/05/2025; Accepted: 13/06/2025; Published: 13/06/2025

Abstrak—Kanker payudara adalah salah satu penyakit paling mematikan dengan prevalensi yang tinggi di seluruh dunia, terutama pada wanita. Kanker payudara menjadi penyebab kematian ketiga terbesar di Indonesia. Berdasarkan data Pusat Globocan, terdapat kasus baru kurang lebih 408.661 dan hampir 242.099 kematian di Indonesia pada 2022. Deteksi dini melalui citra histopatologi sangat penting untuk meningkatkan peluang kesembuhan pasien. Namun, proses diagnosis yang dilakukan secara manual oleh ahli patologi cukup memakan waktu dan berpengaruh pada subjektivitas. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi kanker payudara berbasis citra histopatologi menggunakan VGG-16. Dataset yang akan digunakan terdiri dari gambar histopatologi yang dikelompokkan menjadi 2 kelas, yaitu jinak dan ganas. Data ini melalui beberapa tahap praproses, termasuk splitting dan augmentasi, untuk meningkatkan kualitas data. Hasil pengujian menunjukkan bahwa model ini memiliki pencapaian dengan akurasi 91%, disertai dengan nilai *precision*, *recall*, dan *F1-score* tinggi pada data pengujian. Kinerja model ini lebih baik dibandingkan dengan arsitektur *ensemble* seperti, *MobileNet*, *MobileNetV2*. Temuan ini mengindikasikan bahwa pendekatan yang diajukan dapat menjadi solusi efektif sebagai alat bantu diagnosis kanker payudara berbasis citra histopatologi.

Kata Kunci: CNN; Kanker Payudara; VGG-16; Histopatologi; Klasifikasi Gambar

Abstract—Breast cancer is one of the deadliest diseases with a high prevalence worldwide, especially in women. Breast cancer is the third leading cause of death in Indonesia. Based on Globocan Center data, there will be approximately 408,661 new cases and nearly 242,099 deaths in Indonesia by 2022. Early detection through histopathology images is very important to increase the patient's chances of recovery. However, the diagnosis process carried out manually by pathologists is quite time consuming and affects subjectivity. This study aims to develop a histopathology image-based breast cancer classification system using VGG-16. The dataset to be used consists of histopathology images that are grouped into 2 classes, namely benign and malignant. The data went through several preprocessing stages, including splitting and augmentation, to improve data quality. Test results show that this model achieves 91% accuracy, along with high precision, recall, and F1-scores on the test data. The performance of this model compares favorably with ensemble architectures such as, *MobileNet*, *MobileNetV2*. These findings indicate that the proposed approach can be an effective solution as a histopathology image-based breast cancer diagnosis tool.

Keywords: CNN; Breast Cancer; VGG-16; Histopathology; Image Classification

1. PENDAHULUAN

Kanker payudara merupakan salah satu penyebab kematian tertinggi di dunia, terutama di kalangan perempuan. Di Indonesia, angka kematian akibat kanker payudara tercatat sebesar 38 per 100.000 wanita[1]. Menurut GLOBOCAN 2020, kanker payudara menempati posisi pertama dengan proporsi 16,6% dari seluruh kasus kanker baru di Indonesia[2]. Data dari Kementerian Kesehatan RI menunjukkan bahwa kanker payudara adalah jenis kanker dengan prevalensi tertinggi, serta angka kejadian yang terus meningkat seiring waktu, menjadi penyebab utama kematian akibat kanker pada wanita[3].

Deteksi dini kanker payudara memiliki peran krusial dalam meningkatkan harapan hidup pasien. Akan tetapi, metode diagnosis konvensional masih sangat bergantung pada interpretasi manual gambar histopatologi oleh ahli patologi. Proses ini memakan waktu, bersifat subjektif, serta rentan terhadap variabilitas antar-pengamat[4]. Dalam praktik klinis, interpretasi dilakukan pada citra *Whole Slide Images* (WSI) dalam berbagai tingkat pembesaran, yang menuntut ketelitian tinggi dari analis. Proses ini berpotensi menimbulkan ketidakkonsistenan diagnosis antar pemeriksa dan memperlambat proses pengambilan keputusan klinis[5].

Mengatasi tantangan ini, pendekatan berbasis *Artificial Intelligence* (AI), khususnya *Deep Learning*, mulai banyak digunakan. Salah satu metode yang paling banyak diterapkan adalah *Convolutional Neural Network* (CNN), yang mampu mengekstraksi fitur kompleks dari citra medis tanpa memerlukan rekayasa fitur manual [6]. Model CNN seperti yang dikembangkan oleh Hameed et al.[7] dan Sharif et al.[8] telah terbukti efektif dalam klasifikasi otomatis citra histopatologi kanker payudara, termasuk dalam mengidentifikasi karsinoma dan struktur jaringan yang kompleks. Tantangan signifikan tetap ada, terutama yang berkaitan dengan ketidakseimbangan kelas (*class imbalance*) dalam dataset. Meskipun metode ensemble telah berhasil dalam meningkatkan akurasi klasifikasi citra histopatologi kanker payudara, pendekatan ini memiliki keterbatasan, termasuk penggunaan dataset kecil yang dapat membatasi generalisasi model ke berbagai citra histopatologi yang tidak terwakili dalam set pelatihan [9]. Dalam konteks diagnosis kanker, kesalahan ini sangat berisiko karena dapat menyebabkan keterlambatan pengobatan.

Ketidakeimbangan ini tidak hanya berdampak pada akurasi model secara keseluruhan, tetapi juga pada *F1-score* dan *precision-recall balance*, terutama dalam klasifikasi penyakit berbahaya. Maka dari itu, diperlukan strategi

husus seperti teknik *data augmentation*, *resampling*, serta *cost-sensitive learning* untuk memperbaiki representasi data minoritas dan mengurangi bias model [10].

Sejumlah arsitektur deep learning telah dikembangkan untuk klasifikasi citra medis, di antaranya CNN konvensional, ResNet, dan VGG-16. Arsitektur ResNet memanfaatkan *residual block* untuk memungkinkan pelatihan jaringan yang lebih dalam, tetapi memerlukan sumber daya komputasi yang besar dan sensitif terhadap *hyperparameter tuning* [11]. Model VGG16 berbasis jaringan saraf konvolusional digunakan untuk ekstraksi fitur, dikenal karena efektivitasnya dalam tugas computer vision. VGG16 menggunakan arsitektur yang mendalam dengan filter konvolusi kecil (3x3), menunjukkan kemajuan yang signifikan [12]. Penelitian ini, arsitektur VGG-16 dipilih karena kemampuannya menyeimbangkan antara kedalaman jaringan dan efisiensi komputasi. Beberapa studi sebelumnya menunjukkan efektivitas VGG-16 dalam berbagai domain visual, baik medis [13] maupun non-medis [14], memperlihatkan fleksibilitas arsitektur ini dalam mengenali pola visual kompleks. Selain itu, pendekatan yang kami usulkan melibatkan kombinasi *data augmentation* (rotasi, flipping, scaling) dengan teknik balancing untuk meningkatkan akurasi dan *generalization ability* model.


Penelitian ini berbeda dengan beberapa studi sebelumnya seperti Shilaskar et al. [15] yang menggunakan VGG-16 dan UNet untuk citra ultrasound tanpa menangani isu *class imbalance*, serta Natakusumah et al. [16] yang mengusulkan CNN *multi-scale input* tanpa integrasi augmentasi atau balancing data. Fatima [17] menggunakan *transfer learning* VGG-16 tanpa penguatan data, sementara Balasubramanian et al. [18] dan Mahesa et al. [19] fokus pada metode ensemble yang kompleks tanpa strategi balancing eksplisit dan meskipun metode ensemble telah menunjukkan harapan dalam meningkatkan kinerja klasifikasi, banyak pendekatan tidak secara eksplisit memasukkan strategi penyeimbangan data untuk mengatasi ketidakseimbangan kelas, yang tetap menjadi tantangan kritis dalam analisis citra histopatologi kanker payudara. Penelitian lain dilakukan oleh Hsieh et al. untuk deteksi kanker payudara. Mereka menggunakan model VGG16 pada dataset tolok ukur INbreast [20].

Dengan menggabungkan pendekatan tersebut, penelitian ini bertujuan mengembangkan sistem klasifikasi citra histopatologi kanker payudara yang lebih akurat, efisien, dan objektif. Diharapkan sistem ini dapat menjadi *decision support tool* yang andal bagi tenaga medis dalam proses diagnosis kanker payudara.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Metodologi penelitian merupakan kumpulan langkah-langkah sistematis yang digunakan untuk menyelesaikan suatu masalah penelitian. Tujuan utama dari metodologi ini adalah agar proses penelitian dapat berjalan dengan terstruktur, efisien, dan terorganisir sejak tahap perencanaan hingga evaluasi hasil [13]. Gambar 1 ini menunjukkan tahapan dalam penelitian sebagai berikut.



Gambar 1. Proses Pengolahan Data


Gambar 1 menjelaskan semua tahapan penelitian, dari *acquisition* merupakan proses pengambilan data citra histopatologi kanker payudara. Dataset yang digunakan dalam penelitian ini adalah BreakHis, yang berisi citra digital dari dua jenis kanker, yaitu benign dan malignant, *pre-processing* yaitu citra yang diambil akan melalui tahap pra-pemrosesan untuk menyamakan ukuran, mengurangi noise, dan menyesuaikan format masukan yang dibutuhkan oleh arsitektur CNN. *Pre-processing* membantu meningkatkan kualitas citra sebelum masuk ke model, *splitting data* ini membagi menjadi dua bagian: data latih dan data uji. Pembagian ini bertujuan untuk memisahkan data yang digunakan untuk melatih model dan data yang akan digunakan untuk mengevaluasi performa model, *augmentasi* pada tahap ini dilakukan augmentasi data seperti rotasi, flipping, zooming, dan cropping untuk menambah variasi data latih serta mengatasi masalah *class imbalance*. Masalah ketidakseimbangan kelas (*data imbalance*) dapat menyebabkan model terlalu bias pada kelas mayoritas dan mengabaikan kelas minoritas, sehingga performa klasifikasi terhadap data yang lebih jarang (malignant) menurun. *Modeling* pada model CNN yang digunakan dalam penelitian ini mengimplementasikan arsitektur VGG-16. VGG-16 memiliki keunggulan dalam mengekstraksi fitur visual detail menggunakan kernel berukuran kecil (3x3), sehingga cocok untuk citra histopatologi yang kaya akan pola visual mikro. Dibandingkan dengan arsitektur lain seperti ResNet, VGG-16 lebih sederhana dan stabil untuk dataset kecil hingga menengah. ResNet memiliki kemampuan untuk menyelesaikan masalah vanishing gradient dengan residual block, tetapi memerlukan lebih banyak data dan sumber daya [11]. Oleh karena itu, VGG-16 dipilih karena keseimbangan antara kompleksitas dan akurasi, dan evaluasi yaitu tahap akhir evaluasi model menggunakan

confusion matrix untuk menghitung metrik seperti akurasi, precision, recall, dan F1-score, sehingga dapat diketahui seberapa baik model dalam membedakan antara citra benign dan malignant[19]. Pelatihan model ini menggunakan *deep learning*, implementasi model menggunakan CNN dan arsitektur VGG-16, evaluasi menggunakan model *confusion matrix* untuk mengevaluasi seberapa baik model yang dilatih dalam mengklasifikasikan data.

2.2 Acquisition


Dataset ini memiliki 279 folder yang terdiri dari 2 kelas, yaitu 0 dan 1. Masing-masing kelas memiliki gambar format png yang terdiri dari 198.738 gambar untuk kelas 0 dan 78.786 untuk kelas 1. Penelitian ini menggunakan dataset gambar histopatologi kanker payudara yang ambil dari Kaggle, berikut sumber website yang dapat diakses <https://www.kaggle.com/paultimothymooney/breast-histopathology-images>. Kelas 0 yang dimaksud adalah Benign dan kelas 1 adalah Malignant. Contoh sampel pada kelas 0 dan 1 dapat dilihat seperti gambar berikut.

Gambar 2 berikut menunjukkan contoh citra histopatologi dari kelas 0 atau benign. Citra ini mewakili jaringan payudara yang bersifat jinak, yaitu tidak bersifat ganas dan umumnya tidak menyebar ke jaringan sekitarnya. Visualisasi ini penting untuk memberikan gambaran tentang pola morfologi khas yang membedakan jaringan benign dari jaringan malignant, yang akan digunakan dalam proses pelatihan model klasifikasi berbasis *deep learning*. Berikut sampel kelas 0 atau benign.



Gambar 2. Sampel citra kelas 0 atau Benign

Sebagai perbandingan, gambar berikut menampilkan contoh citra histopatologi dari kelas malignant. Citra ini menggambarkan jaringan payudara yang bersifat ganas, dengan karakteristik sel abnormal yang tumbuh tidak terkendali dan berpotensi menyebar ke jaringan tubuh lainnya. Perbedaan morfologi antara jaringan benign dan malignant menjadi dasar penting dalam proses pelatihan model klasifikasi, agar model mampu membedakan kedua jenis jaringan ini secara akurat dalam sistem diagnosis otomatis berbasis *deep learning*. Berikut sampel kelas 1 atau Malignant.



Gambar 3. Sampel citra kelas 1 atau Malignant

2.3 Pre-processing

Pre-processing data pada gambar histopatologi melakukan integrasi data awal keseluruhan secara manual. Folder awal sejumlah 279, hanya digunakan sebanyak 100 folder. Folder tersebut memiliki masing-masing kelas yang terdiri dari kelas 0 dan kelas 1. Kelas disederhanakan dan diubah, dari semula kelas 0 menjadi kelas Benign dan kelas 1 menjadi Malignant. Total data gambar di agregasikan pada setiap kelas, sehingga folder hanya tersisa kelas Benign dan Malignant. Tujuan agregasi data ini untuk meringkas atau menyederhanakan data yang kompleks menjadi bentuk yang lebih mudah dianalisis dan dipahami, sehingga data gambar menjadi seragam. Hal ini dapat mempercepat pelatihan model dan proses data agar lebih stabil. *Pre-processing* juga melakukan suatu proses awal untuk menambah kualitas gambar histopatologi. Proses ini dimulai dengan mengubah warna gambar RGB. Hasil data ini bertujuan untuk meningkatkan tingkat kecerahan warna objek agar lebih jelas.

2.4 Splitting Data

Splitting data dilakukan dalam penelitian ini untuk melakukan pembagian data dalam 3 tahap berbeda yaitu *train*, *test*, dan *validation*[14]. Proses ini penting dilakukan untuk persiapan sebelum melakukan pengujian model. Pembagian data ini menggunakan rasio 80% untuk data *train* dan 20% untuk data *test*. Tujuan pembagian ini agar dapat memastikan model yang dibangun dapat mengevaluasi dan generalisasi dengan baik. Model arsitektur *train* ini akan dibangun menggunakan *epoch* sejumlah 10.

2.5 Augmentasi Data

Augmentasi data dilakukan sebelum pelatihan model. Augmentasi merupakan proses manipulasi data yang dimiliki untuk mendapatkan data pelatihan yang lebih banyak dan beragam, namun tidak menambah jumlah data asli yang

dimiliki. Teknik ini umumnya digunakan pada penelitian yang membutuhkan jumlah data relatif cukup banyak [16]. Fungsi yang akan dipakai ialah fungsi *ImageDataGenerator*. Augmentasi data menggunakan varian teknik data transformasi seperti, rotasi, *widht*, *height*, *shear*, *zoom*, horional, dan *fill*. Data *train* ini yang akan diaugmentasikan sebagai pengujian model dikarenakan data yang dihasilkan pada *splitting* data tidak seimbang, dengan augmentasi data ini data akan diseimbangkan agar proses klasifikasi data lebih akurat dan baik. Hasil augmentasi data *train* tersebut menghasilkan data yang seimbang sejumlah 54.373 untuk data *train* dan 11.652 untuk data test. Untuk meningkatkan keberagaman data latih dan mengatasi permasalahan ketidakseimbangan kelas (*class imbalance*), dilakukan proses augmentasi data menggunakan fungsi *ImageDataGenerator* dari Keras. Teknik augmentasi ini membantu menghasilkan variasi citra baru dari dataset asli tanpa perlu menambah data secara manual. Beberapa transformasi dilakukan seperti rotasi, pergeseran, *flipping*, hingga *zoom*, sehingga model lebih tangguh dalam mengenali pola visual pada berbagai kondisi citra.

Tabel 1 berikut ini menunjukkan parameter yang digunakan dalam proses augmentasi menggunakan *ImageDataGenerator*. Parameter-parameter ini telah disesuaikan agar menghasilkan variasi citra yang optimal tanpa mengubah karakteristik penting dari jaringan histopatologi. Proses ini menggunakan parameter yang digunakan saat proses augmentasi, parameter yang digunakan seperti berikut ini.

Table 1. Parameter *ImageDataGenerator* yang digunakan dalam proses augmentasi data

Teknik Augmentasi	Parameter
rotation_range	40
width_shift_range	0.2
height_shift_range	0.2
shear_range	0.2
zoom_range	0.2
horizontal_flip	True
fill_mode	'nearest'

2.6 Modeling

Proses penelitian ini disusun berdasarkan perancangan arsitektur Convolutional Neural Network (CNN) yang diimplementasikan menggunakan pendekatan transfer learning untuk tugas klasifikasi citra histopatologi kanker payudara. Transfer learning digunakan untuk memanfaatkan pengetahuan dari model pra-latih yang telah teruji pada dataset berskala besar, sehingga dapat mempercepat proses pelatihan dan meningkatkan akurasi pada dataset yang terbatas. Salah satu arsitektur yang digunakan dalam penelitian ini adalah VGG-16, yang dikenal sebagai arsitektur CNN dalam yang stabil dan memiliki kemampuan ekstraksi fitur visual yang tinggi

Arsitektur VGG-16 terdiri dari 13 lapisan konvolusional dan 3 lapisan fully connected, sehingga totalnya mencapai 16 lapisan. Keunggulan utama dari arsitektur ini terletak pada penggunaannya terhadap kernel kecil berukuran 3x3 dan kedalaman jaringan yang memungkinkan deteksi fitur spasial yang kompleks secara bertahap. VGG-16 telah banyak digunakan dalam berbagai penelitian klasifikasi citra dan merupakan salah satu model awal yang efektif dalam pendekatan transfer learning [14]. Efektivitas model ini terletak pada kemampuannya dalam menyeimbangkan antara kedalaman jaringan dan kemudahan pelatihan, terutama dalam lingkungan dengan keterbatasan data.

Modifikasi terhadap struktur standar VGG-16 dilakukan dengan penambahan lapisan konvolusional (*convolutional layer*) dan lapisan fully connected tambahan. Tujuan dari modifikasi ini adalah untuk meningkatkan kompleksitas dan kapasitas representasi fitur dari model, sehingga mampu menangkap pola-pola yang lebih spesifik dalam citra histopatologi. Penambahan ini diharapkan dapat memperluas kemampuan ekstraksi fitur dan meningkatkan akurasi klasifikasi tanpa secara signifikan menambah beban komputasi.

Setiap lapisan dalam arsitektur memiliki peran tersendiri. Lapisan konvolusional berfungsi untuk mengekstraksi fitur visual dari citra, seperti tepi, tekstur, dan pola jaringan, sedangkan lapisan fully connected bertugas melakukan klasifikasi berdasarkan fitur yang telah diekstraksi sebelumnya. Proses pelatihan dilakukan dengan parameter yang telah disesuaikan melalui proses fine-tuning, agar bobot yang dimiliki model pre-trained dapat disesuaikan dengan karakteristik citra histopatologi kanker payudara yang digunakan dalam studi ini.

Kombinasi antara arsitektur VGG-16, teknik transfer learning, dan penambahan lapisan konvolusional serta fully connected, model ini mampu menunjukkan kinerja yang sangat baik dalam melakukan klasifikasi citra ke dalam dua kelas, yaitu benign dan malignant. Hasil evaluasi menunjukkan bahwa pendekatan ini tidak hanya efektif dari sisi akurasi, tetapi juga efisien dalam proses pelatihan, menjadikannya solusi yang relevan untuk diterapkan dalam sistem diagnosis berbasis citra medis secara otomatis.

2.7 Evaluasi

Evaluasi performa model klasifikasi citra histopatologi kanker payudara merupakan tahap penting untuk mengetahui sejauh mana model yang telah dilatih mampu melakukan prediksi secara akurat. Salah satu metode evaluasi yang digunakan adalah *confusion matrix*, yang berfungsi memberikan informasi detail mengenai hasil prediksi model terhadap kelas sebenarnya. Melalui *confusion matrix*, peneliti dapat mengidentifikasi kekuatan dan kelemahan model

dalam mengenali masing-masing kelas, serta menjadi dasar dalam melakukan penyesuaian arsitektur jaringan, parameter pelatihan, atau strategi augmentasi data. Membandingkan jumlah prediksi dan label aktual pada masing-masing kelas, confusion matrix menjadi alat bantu visual yang efektif dalam menganalisis hasil klasifikasi dan mengarahkan langkah optimasi model secara lebih terfokus.

3. HASIL DAN PEMBAHASAN

3.1 Acquisition

Penelitian ini menggunakan data kanker payudara yang memiliki 2 kelas yaitu Benign dan Malignant. Dataset ini tersedia pada Kaggle sebagai dataset untuk penelitian *deep learning*. Dataset ini dapat digunakan untuk menunjukkan akurasi diagnosa kanker payudara. Dataset yang akan digunakan dari hasil splitting pada data *train*. Berikut visualisasi dataset yang digunakan pada penelitian ini. Penelitian ini, data citra histopatologi kanker payudara dibagi menjadi dua kelas utama, yaitu benign (jinak) dan malignant (ganas). Setelah dilakukan proses augmentasi untuk menyeimbangkan distribusi kelas, jumlah data dari masing-masing kelas menjadi sama besar. Tujuan dari penyeimbangan ini adalah untuk mengurangi bias model terhadap kelas mayoritas dan meningkatkan akurasi klasifikasi, terutama untuk kelas minoritas yang sebelumnya lebih sedikit jumlahnya. Distribusi jumlah data setelah augmentasi ditampilkan secara rinci pada Tabel 2 berikut.

Table 2. Data yang digunakan setelah proses augmentasi

No	Kelas	Jumlah Data
1	Benign	54.373
2	Malignant	54.373
	Total	108.746

3.2 Pre-processing

Tahap *pre-processing* merupakan langkah awal yang sangat penting dalam membangun model klasifikasi berbasis citra. Pada penelitian ini, proses pra-pemrosesan mencakup pembagian dataset ke dalam tiga subset utama, yaitu data pelatihan (*training*), data pengujian (*test*), dan data validasi (*validation*). Dataset yang digunakan terdiri dari citra histopatologi yang telah diagregasikan ke dalam dua kelas utama, yaitu Benign (jinak) dan Malignant (ganas), sesuai dengan kebutuhan klasifikasi biner dalam konteks diagnosis kanker payudara.


Proses agregasi data dilakukan secara manual dengan mengelompokkan citra berdasarkan label klasifikasinya. Meskipun dilakukan secara manual untuk memastikan akurasi dan kesesuaian label, proses ini dapat diotomatisasi menggunakan skrip pemrograman untuk meningkatkan efisiensi dan menghindari kesalahan manusia, terutama ketika menangani dataset berskala besar. Setelah proses agregasi, dilakukan tahap data splitting untuk memisahkan data menjadi bagian pelatihan dan pengujian. Pada penelitian ini, rasio pembagian yang digunakan adalah 80% untuk data pelatihan dan 20% untuk data pengujian, sementara data validasi diambil dari subset pelatihan melalui mekanisme validasi internal selama proses pelatihan model.

Distribusi data yang diperoleh dari proses splitting tersebut menunjukkan adanya ketidakseimbangan kelas (*class imbalance*), di mana jumlah citra pada kelas benign lebih dominan dibandingkan malignant. Ketidakseimbangan ini dapat berdampak negatif terhadap performa model, khususnya dalam mendeteksi kelas minoritas yang secara klinis justru lebih krusial. Untuk mengatasi hal ini, diterapkan strategi data *augmentation* sebagai bagian dari tahap pra-pemrosesan lanjutan. Teknik augmentasi seperti rotasi, *flipping horizontal/vertikal*, dan *scaling* digunakan untuk menambah variasi data kelas minoritas secara sintesis, tanpa mengubah karakteristik inti dari citra.

Penerapan data augmentation tidak hanya bertujuan untuk menyeimbangkan distribusi kelas, tetapi juga untuk meningkatkan generalisasi model dan mengurangi risiko *overfitting*. Dengan memberikan keragaman visual dalam data latih, model diharapkan mampu mengenali pola jaringan histopatologi yang lebih luas dan kompleks. Tahapan pra-pemrosesan yang terstruktur ini menjadi fondasi utama dalam membangun model klasifikasi yang akurat, efisien, dan andal dalam mendukung diagnosis kanker payudara secara otomatis berbasis citra digital.

3.3 Augmentasi

Augmentasi pada penelitian ini merupakan proses utama yang penting untuk dilakukan dan menyeimbangkan hasil data splitting. Proses augmentasi dengan menggunakan fungsi *ImageDataGenerator*. Augmentasi merupakan cara yang digunakan untuk mengurangi *overfitting* model dengan meningkatkan jumlah data pelatihannya. Proses ini memiliki teknik augmentasi pada data latih sebanyak 7 seperti *rescale*, *shear_range*, *zoom_range*, *horizontal_flip*, *vertical_flip*, *rotation_range*, *widht_shift_range*, dan *height_shift_range*. Hasil augmentasi data pada gambar 5 seperti berikut.



Gambar 4. Hasil Augmentasi salah satu contoh citra histopatologi pada kelas malignant

Gambar 5 adalah hasil dari augmentasi yang memiliki berbagai varian posisi, orientasi, dan skala yang tujuannya mempertahankan kualitas gambar. Proses ini bermanfaat dalam meningkatkan kemampuan model untuk mengenali karakteristik kanker payudara dari berbagai sudut kondisi gambar. Penelitian ini mengandalkan model CNN dengan arsitektur VGG-16 sebagai metode utama untuk mengklasifikasikan citra histopatologi kanker payudara. Salah satu keunggulan utama dari penelitian ini adalah penggunaan teknik **augmentasi data**, yaitu proses menambah variasi pada gambar seperti memutar, membalik, atau memperbesar gambar. Teknik ini sangat penting karena dapat membuat model belajar dari lebih banyak variasi gambar, meskipun jumlah data aslinya terbatas. Hasil dari proses augmentasi ini terbukti memberikan dampak besar terhadap peningkatan akurasi model. Artinya, model menjadi lebih baik dalam membedakan antara gambar jaringan yang bersifat jinak (benign) dan ganas (malignant). Dengan kata lain, model bisa memberikan hasil klasifikasi yang lebih tepat dan akurat karena sudah “terlatih” pada data yang lebih beragam.

3.4 Modeling

Pada tahap modeling, penelitian ini menggunakan model Convolutional Neural Network (CNN) dengan arsitektur VGG-16. Arsitektur ini dipilih karena terbukti efektif untuk tugas klasifikasi gambar, termasuk gambar medis. VGG-16 memiliki susunan lapisan yang cukup dalam namun sederhana, sehingga mampu mengenali detail penting pada citra histopatologi. Model ini terdiri dari beberapa lapisan konvolusi kecil dan lapisan fully connected di bagian akhir, yang bekerja sama untuk mengekstraksi dan mengenali pola dari gambar dengan baik.

Pemilihan VGG-16 dalam penelitian ini didasarkan pada performanya yang stabil dan terbukti efektif dalam berbagai studi klasifikasi citra medis, termasuk citra histopatologi kanker payudara. Keunggulan lainnya terletak pada efisiensi pelatihan dan kemampuannya mengekstraksi fitur spasial detail secara konsisten, terutama saat digunakan pada dataset berukuran terbatas [16]. Untuk mengatasi keterbatasan data pelatihan dan mempercepat proses konvergensi model, penelitian ini memanfaatkan model pre-trained VGG-16 yang telah dilatih pada dataset ImageNet. Pendekatan ini dikenal sebagai *transfer learning*, di mana bobot awal dari model digunakan kembali dan hanya lapisan akhir yang dilakukan *fine-tuning* agar model dapat menyesuaikan diri dengan karakteristik dataset citra histopatologi kanker payudara [17], [18].

Meningkatkan kemampuan generalisasi dan mencegah *overfitting*, model juga dilengkapi dengan lapisan dropout pada bagian *fully connected*. Selain itu, teknik augmentasi data digunakan pada tahap pelatihan untuk meningkatkan variasi citra dan mendukung kestabilan pembelajaran. Proses pelatihan dilakukan selama 10 epoch, dengan mempertimbangkan trade-off antara kedalaman pembelajaran dan risiko *overfitting*. Setiap epoch melibatkan proses pembelajaran menyeluruh terhadap seluruh dataset, yang pada jumlah citra yang besar membutuhkan waktu pelatihan relatif lama.

Total waktu yang dibutuhkan untuk menyelesaikan 10 epoch pelatihan adalah sekitar 10 jam. Lamanya waktu pelatihan ini merupakan konsekuensi dari ukuran dataset yang besar serta kompleksitas jaringan VGG-16, yang membutuhkan proses komputasi intensif untuk menyesuaikan bobot jaringan secara optimal. Meskipun demikian, durasi pelatihan yang panjang ini memberikan hasil yang signifikan, di mana model mencapai tingkat akurasi yang tinggi sebesar 91%, didukung pula oleh nilai *recall* dan *F1-score* yang seimbang pada kedua kelas. Hal ini menunjukkan bahwa arsitektur VGG-16 yang dikombinasikan dengan strategi augmentasi data merupakan solusi efektif dalam membangun sistem klasifikasi citra histopatologi kanker payudara yang akurat dan andal.

3.5 Evaluasi

Evaluasi kinerja model dalam penelitian ini dilakukan dengan menggunakan beberapa metrik utama, yaitu *accuracy*, *precision*, *recall*, *F1-score*, dan *support*. Pemilihan metrik evaluasi ini dilakukan karena mampu memberikan gambaran yang lengkap tentang kinerja model, terutama setelah data diseimbangkan melalui proses augmentasi. *Precision* menunjukkan seberapa tepat model dalam memprediksi sebuah kelas, sedangkan *recall* menunjukkan seberapa baik model menemukan semua data yang benar dari kelas tersebut. *F1-score* digunakan untuk melihat keseimbangan antara *precision* dan *recall*. Sementara itu, *support* menunjukkan jumlah data sebenarnya dari masing-masing kelas yang digunakan saat evaluasi. Berdasarkan hasil pengujian pada penelitian ini, model VGG-16 dan augmentasi menunjukkan performa seperti pada tabel 3 berikut.

Table 3. Hasil performa Arsitektur VGG-16 dengan Augmentasi dengan Augmentasi

Class	Precision	Recall	F1-score	Support
Benign	0.88	0.95	0.92	5463
Malignant	0.95	0.87	0.91	5412

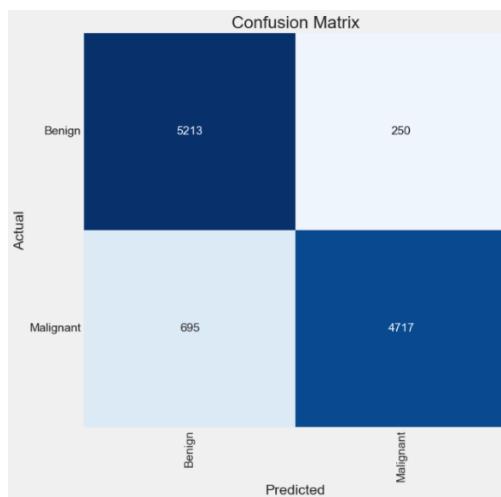
Class	Precision	Recall	F1-score	Support
accuracy			0.91	10875
macro avg	0.92	0.91	0.91	10875
weighted avg	0.92	0.91	0.91	10875

Berdasarkan hasil pengujian yang ditampilkan pada Tabel 3, model CNN dengan arsitektur VGG-16 yang dikombinasikan dengan teknik data augmentation menghasilkan performa yang sangat baik. Untuk kelas benign, precision sebesar 0.88 dan recall sebesar 0.95 menghasilkan F1-score 0.92, menunjukkan bahwa model mampu mendeteksi kasus non-kanker secara akurat. Sementara itu, pada kelas malignant, precision mencapai 0.95 dengan recall 0.87, menghasilkan F1-score sebesar 0.91, menandakan bahwa model juga sangat baik dalam mengidentifikasi kasus kanker. Akurasi keseluruhan model mencapai 91%, dengan nilai *macro average* dan *weighted average* yang konsisten, yaitu masing-masing 0.91. Hal ini mengindikasikan bahwa model memiliki kinerja yang seimbang pada kedua kelas.

Hasil evaluasi tersebut, dapat disimpulkan bahwa pendekatan single classifier dengan arsitektur VGG-16, meskipun tidak menggabungkan berbagai model seperti pada *ensemble methods*, tetap mampu menghasilkan prediksi yang akurat dan stabil. Tingginya nilai *F1-score* pada kedua kelas menunjukkan bahwa model memiliki keseimbangan yang baik antara kemampuan mendeteksi (*recall*) dan ketepatan klasifikasi (*precision*), yang sangat penting dalam konteks diagnosis medis, terutama untuk menghindari kesalahan klasifikasi pada kelas minoritas (*malignant*).

Evaluasi performa model juga dilakukan menggunakan confusion matrix seperti yang ditampilkan pada Table 3. Hasil tersebut, terlihat bahwa model berhasil mengklasifikasikan 5.213 citra benign dan 4.717 citra malignant dengan benar. Namun, masih terdapat kesalahan klasifikasi, yaitu 250 citra benign yang salah diprediksi sebagai malignant, dan 695 citra malignant yang salah diklasifikasikan sebagai benign. Melalui visualisasi ini, peneliti dapat dengan mudah mengidentifikasi jenis kesalahan yang terjadi, seperti false positive dan false negative, sehingga dapat digunakan sebagai acuan untuk meningkatkan akurasi model di tahap selanjutnya.

Hasil dari confusion matrix yang mendukung nilai-nilai pada Tabel 3 menunjukkan bahwa model mampu mempertahankan proporsi prediksi benar yang tinggi pada kedua kelas, serta meminimalkan kesalahan klasifikasi. Hal ini menjadi bukti bahwa integrasi VGG-16 dan augmentasi data dapat menjadi strategi efektif dalam pengembangan sistem bantu diagnosis otomatis berbasis citra histopatologi kanker payudara. Hasil *Confusion matrix* seperti gambar 6 berikut.



Gambar 5. Hasil *Confusion Matrix* dalam evaluasi performa model

Beberapa studi terdahulu yang menerapkan metode *Convolutional Neural Network* (CNN), khususnya arsitektur VGG-16, dalam klasifikasi citra histopatologi kanker payudara telah menunjukkan hasil yang bervariasi tergantung pada jenis dataset, teknik preprocessing, dan strategi pelatihan yang digunakan. Misalnya, Fatima et al. [17] melaporkan akurasi tinggi (>90%) namun menghadapi masalah *overfitting* pada kelas minoritas karena tidak menerapkan teknik balancing data. Shilaskar et al. [15] yang menggabungkan VGG-16 dengan UNet untuk citra ultrasound mencatat recall yang lebih rendah pada kelas ganas dibandingkan benign. Natakusumah & Ernastuti [16] menggunakan pendekatan multi-feature tetapi tidak menyertakan augmentasi intensif, menghasilkan model yang kurang robust pada data baru. Sementara itu, Balasubramanian et al. [18] menggunakan ansambel model besar yang unggul dalam akurasi, namun tidak efisien secara komputasi dan sulit diimplementasikan dalam skala klinis. Dalam penelitian ini, pendekatan kombinasi *transfer learning* VGG-16 dengan strategi *data augmentation* dan *class balancing* berhasil meningkatkan recall dan F1-score pada kelas minoritas (*malignant*), yang sebelumnya menjadi tantangan utama. Oleh karena itu, hasil penelitian ini menunjukkan peningkatan performa yang lebih seimbang antar kelas dan efektivitas lebih tinggi pada pengenalan kanker ganas dibandingkan dengan studi sebelumnya. Meskipun arsitektur ini dikenal unggul dalam mengekstraksi fitur visual detail dan memiliki struktur jaringan yang stabil, performa model dalam studi-studi tersebut belum mencapai hasil yang optimal. Salah satu faktor penyebabnya adalah

ketiadaan penerapan strategi augmentasi data, yang berperan penting dalam memperkaya variasi data latih dan memperbaiki distribusi kelas yang tidak seimbang.

Berdasarkan kondisi tersebut, penelitian ini dirancang untuk mengintegrasikan strategi augmentasi data (rotasi, flipping, dan scaling) dengan arsitektur CNN VGG-16. Kombinasi ini mampu meningkatkan performa klasifikasi, tidak hanya dari sisi akurasi keseluruhan, tetapi juga dalam meningkatkan sensitivitas model terhadap kelas minoritas (malignant), yang sangat penting dalam konteks diagnosis kanker payudara.

Sebagai bagian dari analisis komparatif, disajikan konstruksi tabel perbandingan terhadap hasil yang diperoleh dari sejumlah penelitian terdahulu yang menggunakan CNN dan/atau dataset histopatologi, termasuk yang menerapkan arsitektur VGG-16. Melalui perbandingan ini, terlihat bahwa penerapan augmentasi data dalam penelitian ini menghasilkan peningkatan performa yang signifikan dibandingkan pendekatan yang tidak menyertakan teknik tersebut. Hal ini menggarisbawahi pentingnya pemilihan strategi praproses yang tepat dalam membangun sistem klasifikasi citra medis yang akurat dan robust. Tabel 4 dibawah ini hasil perbandingan penelitian ini dengan penelitian terdahulu.

Table 4. Konstruksi Perbandingan peneliti terdahulu dengan terbaru

<i>Authors</i>	<i>Algoritma</i>	<i>Features Method</i>	<i>Preprocessing</i>	<i>Dataset</i>	<i>Accuracy</i>
[6]	CNN (VGG-16, ResNet-50)	RGB image	-	Histopatology Dataset	89%
[19]	Ensemble CNN	RGB image	-	Breast Histopatology image	86%
[16]	CNN Multi-sclae Input	RGB image	-	Breast Cancer Dataset	88%
[4]	CNN + Transfer Learning	RGB image	Resizing, Normalization	Local histopathology	89%
[5]	Various classifier	Multi-feature (spatial & texture)	Image resizing	breakKhis (400xmagnification)	88%
Penelitian ini	CNN (VGG-16)	RGB image	Augmentasi	Histopatologi (Breakhis)	91%

Tabel 4 menyajikan hasil perbandingan antara beberapa penelitian terdahulu dengan penelitian ini dalam konteks klasifikasi citra histopatologi kanker payudara. Perbandingan ini mencakup arsitektur CNN yang digunakan, metode praproses data, jenis dataset, serta performa model dalam bentuk nilai akurasi. Berdasarkan hasil perbandingan tersebut, dapat disimpulkan bahwa penelitian ini berhasil mencapai tingkat akurasi tertinggi, yaitu sebesar 91%, melalui penerapan arsitektur CNN VGG-16 yang dikombinasikan dengan teknik *data augmentation*. Nilai ini menunjukkan peningkatan yang signifikan dibandingkan pendekatan lain, termasuk metode *ensemble CNN* yang sebelumnya telah banyak digunakan..

Keunggulan model dalam penelitian ini membuktikan bahwa penggunaan *single classifier* seperti VGG-16, jika dioptimalkan dengan strategi praproses yang tepat, mampu menghasilkan performa yang sangat kompetitif. Hal ini menjadi poin penting karena sebagian besar penelitian sebelumnya menggunakan metode *ensemble* atau arsitektur yang lebih kompleks dengan hasil yang tidak melebihi akurasi yang dicapai oleh penelitian ini. Dengan demikian, kompleksitas tinggi dari metode ensemble belum tentu selalu berbanding lurus dengan peningkatan kinerja model, terutama jika arsitektur tunggal telah dioptimalkan secara efisien.

Kontribusi signifikan lainnya berasal dari penerapan strategi *data augmentation*. Teknik augmentasi seperti rotasi, flipping, dan scaling memberikan variasi data yang memperkaya representasi visual selama pelatihan. Hal ini terbukti efektif dalam meningkatkan generalisasi model terhadap data uji dan mengatasi masalah ketidakseimbangan kelas, yang sering menjadi tantangan dalam klasifikasi citra medis. Kombinasi antara VGG-16 dan augmentasi data, penelitian ini mampu membangun sistem klasifikasi yang tidak hanya akurat tetapi juga efisien dan praktis untuk diterapkan.

Secara keseluruhan, temuan dalam penelitian ini menunjukkan bahwa kombinasi arsitektur VGG-16 dan augmentasi data merupakan pendekatan yang optimal dalam pengembangan sistem bantu diagnosis kanker payudara berbasis citra histopatologi. Tingkat akurasi yang tinggi, efisiensi pelatihan, serta ketepatan dalam mengenali area patologis menjadikan model ini layak untuk diadaptasi ke dalam sistem klinis nyata sebagai alat bantu yang efektif dalam mendukung pengambilan keputusan medis. Penelitian ini juga membuka peluang bagi pengembangan sistem klasifikasi yang ringan namun tetap memiliki kinerja tinggi, khususnya dalam konteks penerapan di fasilitas kesehatan dengan sumber daya terbatas.

4. KESIMPULAN

Berdasarkan seluruh rangkaian proses penelitian, dapat disimpulkan bahwa penerapan arsitektur VGG-16 dengan dukungan teknik augmentasi sederhana seperti rotasi, flipping, dan scaling mampu meningkatkan performa klasifikasi

citra histopatologi kanker payudara secara signifikan. Model yang dibangun menunjukkan hasil evaluasi yang kompetitif, khususnya dalam metrik akurasi, recall, dan F1-score, serta menghasilkan representasi klasifikasi yang baik sebagaimana ditunjukkan pada confusion matrix. Temuan ini menunjukkan bahwa meskipun menggunakan pendekatan yang relatif sederhana, hasil penelitian ini mampu melampaui atau menyamai performa dari beberapa studi sebelumnya yang menggunakan pendekatan serupa. Dengan demikian, penelitian ini memberikan kontribusi nyata dalam pengembangan sistem pendeteksi kanker berbasis citra yang efisien dan potensial untuk diterapkan lebih lanjut di lingkungan medis.

REFERENCES

- [1] A. Yusnina, I. Muhimmah, and I. Fidianingsih, “Ekstraksi Fitur untuk Sel Abnormal Pleomorfik pada Kanker Payudara,” *Automata*, vol. 2, no. 2, p. 7, 2021, doi: <https://doi.org/10.30812/matrik.v22i3.2803>.
- [2] F. Bray *et al.*, “Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries,” *CA. Cancer J. Clin.*, vol. 74, no. 3, pp. 229–263, 2024, doi: 10.3322/caac.21834.
- [3] S. Kumar *et al.*, “BCCHI - HCNN : Breast Cancer Classification from Histopathological Images Using Hybrid Deep CNN Models,” *J. Imaging Informatics Med.*, vol. 38, no. 3, pp. 1690–1703, 2025, doi: 10.1007/s10278-024-01297-2.
- [4] D. R. Chandranegara, F. H. Pratama, S. Fajrianur, M. Rizky, E. Putra, and Z. Sari, “Automated Detection of Breast Cancer Histopathology Image Using Convolutional Neural Network and Transfer Learning,” *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 22, no. 3, pp. 455–468, 2023, doi: 10.30812/matrik.v22i3.2803.
- [5] T. S. Sheikh, Y. Lee, and M. Cho, “Histopathological classification of breast cancer images using a multi-scale input and multi-feature network,” *Cancers (Basel)*, vol. 12, no. 8, pp. 1–21, 2020, doi: 10.3390/cancers12082031.
- [6] I. Idawati, D. P. Rini, A. Primanita, and T. Saputra, “Klasifikasi Kanker Payudara Menggunakan Metode Convolutional Neural Network (CNN) dengan Arsitektur VGG-16,” *J. Sist. Komput. dan Inform.*, vol. 5, no. 3, p. 529, 2024, doi: 10.30865/json.v5i3.7553.
- [7] Z. Hameed, S. Zahia, B. Garcia-Zapirain, J. Javier Aguirre, and A. María Vanegas, “Breast Cancer Histopathology Image Classification Using an Ensemble of Deep Learning Models,” *Sensors (Basel)*, vol. 20, no. 16, Aug. 2020, doi: 10.3390/s20164373.
- [8] M. A. Wakili *et al.*, “Classification of Breast Cancer Histopathological Images Using DenseNet and Transfer Learning,” *Wiley Online Libr.*, vol. 2022, 2022, doi: 10.1155/2022/8904768.
- [9] C. Ben Rabah, A. Sattar, A. Ibrahim, and A. Serag, “A Multimodal Deep Learning Model for the Classification of Breast Cancer Subtypes,” *Diagnostics*, vol. 15, no. 8, pp. 1–17, 2025, doi: 10.3390/diagnostics15080995.
- [10] U. K. Lilhore *et al.*, “Hybrid convolutional neural network and bi-LSTM model with EfficientNet-B0 for high-accuracy breast cancer detection and classification,” *Sci. Rep.*, vol. 15, no. 1, p. 12082, Apr. 2025, doi: 10.1038/s41598-025-95311-4.
- [11] W. Setiawan, “Klasifikasi Citra Histopatologi Kanker Payudara menggunakan Data Resampling Random dan Residual Network,” *J. Sist. Inf. Bisnis*, vol. 11, no. 1, pp. 70–77, 2021, doi: 10.21456/vol11iss1pp70-79.
- [12] L. Solorzano, S. Robertson, B. Acs, J. Hartman, and M. Rantalainen, “Ensemble-based deep learning improves detection of invasive breast cancer in routine histopathology images,” *Heliyon*, vol. 10, no. 12, p. e32892, 2024, doi: 10.1016/j.heliyon.2024.e32892.
- [13] N. I. Sanusi, S. Ramadhani, and M. Irsyad, “Analisa Gambar X-Ray Mammography dengan Convolution Neural Network pada Deep Learning dengan Arsitektur Resnet,” *J. Sist. Komput. dan Inform.*, vol. 4, no. 4, p. 26, 2023, doi: 10.30865/json.v4i4.6365.
- [14] R. Anggriawan, V. Leonard, E. Tanuwijaya, and N. Sugianto, “Pengembangan Arsitektur VGG16 dan DCNN7 pada Convolutional Neural Network dalam Melakukan Klasifikasi Pose Yoga VGG16 and DCNN7 Architecture Improvement on Convolutional Neural Network in Classifying Yoga Pose,” *J. Sist. dan Teknol. Inf.*, vol. 11, no. 2, pp. 314–322, 2023, doi: 10.26418/justin.v11i2.55533.
- [15] S. Shilaskar, S. Bhatlawande, and M. Talewar, “Classification and Segmentation of Breast Tumor Ultrasound Images using VGG-16 and UNet,” *Biomed. Pharmacol. J.*, vol. 18, no. March, pp. 569–580, 2025, doi: <https://dx.doi.org/10.13005/bpj/3109>.
- [16] G. P. Natakusumah and E. Ernastuti, “Implementasi Metode CNN Multi-Scale Input dan Multi-Feature Network untuk Dugaan Kanker Payudara,” *JOINTECS (Journal Inf. Technol. Comput. Sci.)*, vol. 7, no. 2, p. 10, 2022, doi: 10.31328/jointecs.v7i2.3637.
- [17] T. Fatima, “Application of VGG16 Transfer Learning for Breast Cancer Detection,” *Information*, vol. 16, no. 227, p. 20, 2025, doi: <https://doi.org/10.3390/info16030227>.
- [18] A. A. Balasubramanian *et al.*, “Ensemble Deep Learning-Based Image Classification for Breast Cancer Subtype and Invasiveness Diagnosis from Whole Slide Image Histopathology,” *Cancers (Basel)*, vol. 16, no. 12, 2024, doi: 10.3390/cancers16122222.
- [19] G. A. Mahesa, A. E. Minarno, and Y. Azhar, “Klasifikasi Citra Histologi Kanker Payudara Menggunakan Metode Ensemble CNN,” *J. Repos.*, vol. 4, no. 3, pp. 373–384, 2024, doi: 10.22219/repositor.v4i3.31097.
- [20] 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.