

PERANCANGAN DAN IMPLEMENTASI SISTEM KLASIFIKASI CITRA HISTOPATOLOGI KANKER PAYUDARA BERBASIS KOMBINASI METODE GLCM DAN EFFICIENTNET

Doni Prasetyo¹, Fawaidul Badri², Bambang Minto Basuki³

^{1,2,3} Teknik Elektro, Universitas Islam Malang; Jl, Mayjen Haryono No.193, Kec. Lowokwaru, Kota Malang, Jawa Timur. 65144

Keywords :

Hybrid Deep Learning;
Image Classification;
Texture Feature Extraction;

Correspondent Email:

fawaidulbadri@unisma.ac.id

Abstrak. Kanker payudara memerlukan metode diagnosis yang akurat dan objektif untuk mendukung deteksi dini. Penelitian ini mengusulkan sistem klasifikasi citra histopatologi kanker payudara menggunakan metode Gray Level Co-occurrence Matrix (GLCM), EfficientNet, serta pendekatan hybrid yang menggabungkan keduanya. Hasil pengujian menunjukkan bahwa metode GLCM menghasilkan akurasi validasi sebesar 74%, sementara EfficientNet mencapai akurasi hingga 97%. Pendekatan hybrid GLCM–EfficientNet memberikan performa terbaik dengan akurasi mendekati 98% dan tingkat kesalahan klasifikasi yang sangat rendah. Temuan ini menunjukkan bahwa integrasi fitur tekstur dan fitur deep learning mampu meningkatkan kinerja klasifikasi secara signifikan. Penelitian selanjutnya diarahkan pada validasi klinis dan pengembangan sistem berbasis aplikasi untuk mendukung diagnosis medis.



Copyright © [JITET](http://www.jitet.org) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract. A maximum Breast cancer requires accurate and objective diagnostic methods to support early detection. This study proposes a histopathological image classification system using Gray Level Co-occurrence Matrix (GLCM), EfficientNet, and a hybrid combination of both approaches. Experimental results show that the GLCM-based method achieves a validation accuracy of 74%, while EfficientNet reaches up to 97% accuracy. The hybrid GLCM–EfficientNet approach provides the best performance, achieving approximately 98% accuracy with minimal misclassification. These results indicate that combining handcrafted texture features with deep learning representations significantly improves classification performance. Future work will focus on clinical validation and the development of application-based diagnostic support systems.

1. PENDAHULUAN

Kanker payudara merupakan penyakit yang disebabkan oleh pertumbuhan sel abnormal yang tidak terkendali pada jaringan payudara dan berpotensi menyebar ke organ lain apabila tidak terdeteksi sejak dini[1]. Penyakit ini umumnya bermula pada saluran atau lobulus penghasil susu dan relatif lebih mudah ditangani pada tahap awal. Namun, ketika berkembang menjadi invasif, kanker payudara dapat mengancam keselamatan pasien,

sehingga diagnosis dini dan akurat menjadi aspek yang sangat krusial[1]. karena mampu menampilkan struktur jaringan secara detail hingga tingkat seluler.

Dalam praktik klinis, analisis citra histopatologi merupakan salah satu metode utama dalam diagnosis kanker payudara karena mampu menampilkan karakteristik morfologi dan tekstur jaringan secara detail hingga tingkat seluler[2]. Meskipun demikian, analisis citra histopatologi secara manual masih

memiliki keterbatasan, antara lain ketergantungan pada keahlian patolog, waktu analisis yang relatif lama, serta potensi subjektivitas dalam interpretasi hasil [2],[3]. Kondisi ini mendorong pengembangan sistem klasifikasi citra berbasis komputasi yang lebih cepat, objektif, dan konsisten [4].

Metode ekstraksi fitur tekstur klasik seperti Gray Level Co-occurrence Matrix (GLCM) telah lama digunakan dalam pengolahan citra medis karena kemampuannya yang sangat peka dalam menangkap pola spasial dan karakteristik tekstur lokal. Penelitian sebelumnya menunjukkan bahwa GLCM mampu mencapai akurasi hingga 89,3% dalam klasifikasi tumor payudara[5]. Namun, fitur GLCM bersifat *handcrafted* dan statis, sehingga yang mengakibatkan tingkat akurasi kurang memuaskan pada sebuah model.

Seiring perkembangan kecerdasan buatan, metode deep learning berbasis Convolutional Neural Network (CNN) banyak diterapkan dalam klasifikasi citra medis. EfficientNet merupakan salah satu arsitektur CNN yang dirancang untuk menyeimbangkan akurasi dan efisiensi komputasi melalui pendekatan compound scaling[6]. EfficientNet telah menunjukkan performa yang baik pada berbagai kasus citra medis, termasuk kanker payudara, terutama dengan dukungan augmentasi data[7]. Namun demikian, pendekatan deep learning cenderung menitikberatkan pada fitur global dan belum sepenuhnya mengeksplorasi informasi tekstur lokal secara eksplisit.

Pendekatan hybrid yang menggabungkan fitur tekstur dan fitur morfologis secara konseptual didukung oleh penelitian[8]., yang menunjukkan bahwa integrasi informasi tekstur lokal dan struktur global mampu meningkatkan performa klasifikasi tumor secara signifikan. Namun, hingga saat ini, masih terbatas penelitian yang mengintegrasikan fitur tekstur GLCM dan fitur deep learning EfficientNet secara terpadu dalam satu sistem klasifikasi citra histopatologi kanker payudara. Hal ini menunjukkan adanya kesenjangan penelitian yang perlu dikaji lebih lanjut.

Berdasarkan permasalahan tersebut, penulis mengusulkan perancangan sistem klasifikasi citra histopatologi kanker payudara berbasis metode hybrid GLCM–EfficientNet, yang

bertujuan untuk menggabungkan keunggulan fitur tekstur lokal dan kemampuan representasi fitur global dari deep learning. Diharapkan pendekatan ini dapat menghasilkan sistem klasifikasi dengan hasil akurasi yang tinggi, cepat, dan objektif dibandingkan metode tunggal, serta memberikan kontribusi signifikan bagi diagnosis dini kanker payudara

2. TINJAUAN PUSTAKA

Analisis citra histopatologi merupakan salah satu metode utama untuk diagnosis kanker payudara karena mampu menampilkan struktur jaringan hingga tingkat seluler, yang membantu membedakan antara jaringan jinak dan ganas [1]. Diagnosis manual citra histopatologi seringkali memerlukan keahlian tinggi dan waktu yang lama, sehingga mendorong pengembangan sistem berbasis komputasi untuk klasifikasi citra yang lebih cepat dan objektif.

Gray Level Co-occurrence Matrix (GLCM) merupakan metode klasik untuk ekstraksi fitur tekstur, yang mampu merepresentasikan hubungan intensitas piksel pada jarak dan arah tertentu untuk menghasilkan parameter statistik seperti kontras, korelasi, energi, dan homogenitas. Dalam klasifikasi citra medis, termasuk citra mammogram atau histopatologi, GLCM terbukti efektif dalam menangkap pola tekstur mikro yang berguna untuk membedakan tipe jaringan kanker dan non-kanker [9]. Secara Matematis GLCM dituliskan dalam bentuk Matriks probabilitas $P(i, j)$ yang dihasilkan menggambarkan frekuensi kemunculan pasangan tingkat keabuan i dan j , sehingga berbagai parameter statistik orde kedua dapat dihitung untuk merepresentasikan karakteristik tekstur citra. Parameter utama yang digunakan dalam penelitian ini meliputi kontras, energi, homogenitas, dan korelasi yang masing-masing dirumuskan pada Persamaan (1)–(4). Keempat parameter tersebut banyak digunakan dalam analisis tekstur citra medis karena mampu menangkap perbedaan distribusi intensitas piksel antara jaringan normal dan jaringan kanker[10].

$$\text{Contrast} = \sum_{i=10}^{255} \sum_{j=10}^{255} (i - j)^2 P(i, j) \quad (1).$$

$$Disimilarity = \sum_{i=10}^{255} \sum_{j=10}^{255} |i - j|P(i, j) \quad (2).$$

$$Homogeneity = \sum_{i=10}^{255} \sum_{j=10}^{255} \frac{P(i, j)}{1+(i-j)^2} \quad (3).$$

Corelitation =

$$\sum_{i=10}^{255} \sum_{j=10}^{255} \frac{(i-\mu)(j-\mu)}{\sigma^2} P(i, j) \quad (4).$$

Dengan $P(i, j)$ adalah elemen matriks GLCM yang telah dinormalisasi, μ adalah nilai rata-rata tingkat keabuan, dan σ adalah standar deviasi. Parameter-parameter ini digunakan untuk menggambarkan karakteristik tekstur citra secara kuantitatif sehingga dapat dimanfaatkan sebagai fitur masukan dalam proses klasifikasi citra medis berbasis pembelajaran mesin [10].

Selain pada mammogram, GLCM juga banyak diterapkan pada berbagai domain citra medis, termasuk pengklasifikasian pola tekstur pada citra X-ray pneumonia [11]. Metode ini efektif karena mampu mengekstraksi fitur statistik seperti Contrast dan Homogeneity yang sensitif terhadap perubahan halus pada jaringan paru. Kemampuan GLCM dalam mengenali pola infiltrat yang tidak teratur membuktikan bahwa analisis tekstur ini sangat krusial untuk meningkatkan akurasi diagnosis medis secara objektif.

Deep learning, terutama Convolutional Neural Network (CNN), telah menjadi metode unggulan dalam klasifikasi citra medis karena kemampuannya mengekstraksi fitur hierarkis secara otomatis. Penggunaan CNN dalam analisis histopatologi telah terbukti mampu menyamai performa ahli patologi dalam tugas-tugas kompleks seperti deteksi dan penentuan stadium tumor [12]. Hal ini dikarenakan CNN dapat mengenali struktur seluler dan pola keganasan yang sulit dideteksi secara manual, sehingga meningkatkan objektivitas dan efisiensi diagnosis di laboratorium.

EfficientNet merupakan arsitektur CNN yang mengoptimalkan skalabilitas jaringan melalui pendekatan *compound scaling*, sehingga mampu mencapai keseimbangan antara akurasi dan efisiensi komputasi. Berbagai penelitian menunjukkan bahwa EfficientNet dan variannya efektif dalam

klasifikasi citra histopatologi kanker payudara, termasuk pada grading IDC dan deteksi kanker payudara melalui integrasi dengan mekanisme tambahan seperti GRU dan attention [13],[14]. EfficientNet memperkenalkan konsep penskalaan jaringan secara simultan pada tiga dimensi utama, yaitu kedalaman (*depth*), lebar (*width*), dan resolusi input (*resolution*), sehingga peningkatan kapasitas model dapat dilakukan secara seimbang. Secara matematis, hubungan penskalaan tersebut dirumuskan pada Persamaan (9), sedangkan kendala kompleksitas komputasi dinyatakan pada Persamaan (10)[6].

$$depth : \alpha^\phi, width : \beta^\phi, resolution : \gamma^\phi \quad (5).$$

Dengan α, β dan γ merupakan konstanta positif yang di peroleh dari pencarian hiperparameter sedangkan ϕ adalah *scaling coefficient* yang mengontrol tingkat perluasan model. Untuk menjaga efisiensi komputasi, EfficientNet menetapkan kendala kompleksitas FLOPs sebagaimana ditunjukkan pada Persamaan (10).[6]

$$\alpha \cdot \beta^2 \cdot \gamma \approx 2 \quad (6).$$

Kendala tersebut memastikan bahwa setiap peningkatan satu unit koefisien skala ϕ akan meningkatkan jumlah operasi komputasi secara terkontrol, sehingga kapasitas model meningkat tanpa lonjakan parameter yang berlebihan. Melalui pendekatan ini, EfficientNet mampu mencapai performa tinggi pada berbagai tugas klasifikasi citra medis, termasuk pada dataset histopatologi seperti BreakHis.

Pendekatan hybrid yang mengombinasikan keunggulan arsitektur CNN dengan teknik tingkat lanjut terbukti memberikan performa yang lebih unggul dalam klasifikasi citra histopatologi dibandingkan penggunaan CNN tunggal. Sebagai contoh, integrasi model EfficientNet dengan Gated Recurrent Unit (GRU) dan mekanisme atensi (attention mechanism) mampu mengekstraksi fitur spasial sekaligus menangkap ketergantungan sekuensial antar-fragmen citra secara lebih presisi [15]. Mekanisme atensi ini memungkinkan model untuk secara selektif memprioritaskan area jaringan yang paling

relevan dengan indikasi keganasan, sehingga mampu membedakan variasi seluler yang sangat halus dan meningkatkan metrik evaluasi seperti akurasi serta skor F1 pada dataset kanker payudara yang kompleks.

Penelitian lain menyoroti konsep fusi fitur antara CNN dan fitur statistik klasik seperti GLCM atau tekstur lainnya untuk memperkaya representasi fitur citra medis. Pendekatan ini terbukti meningkatkan akurasi klasifikasi dengan menggabungkan fitur handcrafted dan deep features dalam satu pipeline, menunjukkan pentingnya kombinasi kedua metode untuk performa yang optimal [16]. Integrasi tersebut memungkinkan model CNN menangkap pola global dan struktur kompleks citra, sementara fitur statistik seperti GLCM mampu merepresentasikan karakteristik tekstur mikro yang sering muncul pada jaringan histopatologi kanker payudara. Beberapa studi terbaru juga melaporkan bahwa strategi fusi fitur berbasis feature concatenation maupun ensemble learning dapat meningkatkan stabilitas model serta kemampuan generalisasi pada dataset histopatologi seperti BreakHis. Dengan demikian, kombinasi antara pendekatan deep learning dan fitur tekstur klasik menjadi strategi yang menjanjikan untuk meningkatkan ketepatan diagnosis berbasis citra medis optimal [16].

3. METODE PENELITIAN

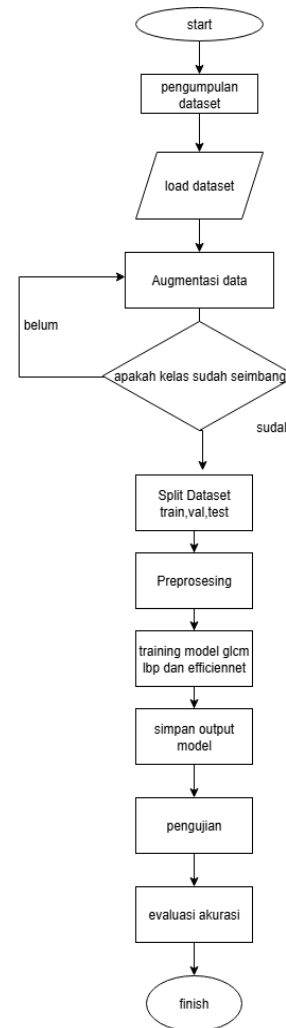
3.1. Desain Penelitian dan Dataset

Penelitian ini menggunakan pendekatan kuantitatif eksperimental untuk mengembangkan dan mengevaluasi sistem klasifikasi citra histopatologi kanker payudara berbasis ekstraksi fitur tekstur Gray Level Co-occurrence Matrix (GLCM) dan model deep learning EfficientNet. Seluruh tahapan penelitian dirancang secara sistematis mulai dari pengambilan dataset, pengolahan data, pelatihan model, hingga evaluasi kinerja sistem.

Dataset yang digunakan merupakan dataset citra histopatologi kanker payudara yang diperoleh dari sumber terbuka melalui platform Kaggle. Dataset terdiri dari delapan kelas, yaitu Adenosis, Fibroadenoma, Tubular Adenoma, Phyllodes Tumor, Ductal Carcinoma, Lobular Carcinoma, Mucinous Carcinoma, dan Papillary Carcinoma. Seluruh

citra diseragamkan ke ukuran 224×224 piksel dengan format JPEG (.jpg).

ntuk memberikan gambaran yang lebih jelas mengenai tahapan dan alur penelitian yang dilakukan, keseluruhan proses penelitian disajikan dalam bentuk flowchart sebagaimana ditunjukkan pada **Gambar 1**.



Gambar 1 Flowcart Penelitian

Gambar 1 menunjukkan alur penelitian yang digunakan dalam studi ini. Proses penelitian diawali dengan pengumpulan dataset citra, yang selanjutnya melalui tahap pra-pemrosesan untuk meningkatkan kualitas data dan memastikan keseragaman input. Setelah itu, fitur tekstur diekstraksi menggunakan metode Gray Level Co-occurrence Matrix (GLCM) sebagai representasi karakteristik citra. Fitur yang diperoleh kemudian digunakan sebagai masukan dalam proses pelatihan dan pengujian

model klasifikasi berbasis EfficientNet. Tahap akhir penelitian meliputi evaluasi performa model menggunakan metrik evaluasi standar untuk menilai efektivitas metode yang diusulkan.

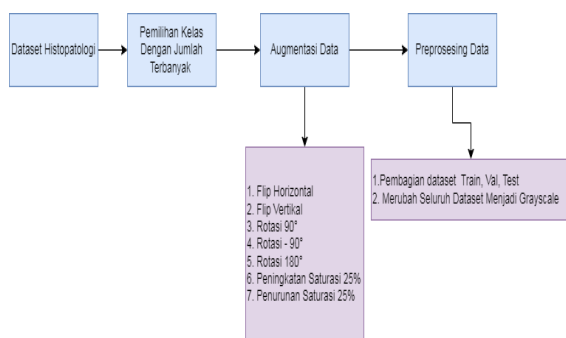
3.2. Pengolahan Data dan Blok Diagram Sistem Augmentasi

3.2.1. Analisis Distribusi Kelas Dataset

Tahap awal pengolahan data dimulai dengan melakukan analisis distribusi jumlah citra pada setiap kelas. Analisis ini bertujuan untuk mengidentifikasi kelas mayoritas dan kelas minoritas pada dataset. Kelas dengan jumlah citra terbanyak digunakan sebagai acuan target jumlah data setelah proses augmentasi.

3.2.2. Sistem Augmentasi Dataset

Proses augmentasi dataset dirancang sebagai sebuah sistem terstruktur yang direpresentasikan dalam bentuk blok diagram sistem augmentasi dataset sebagaimana ditunjukkan pada **Gambar 2**. Blok diagram tersebut menggambarkan alur pemrosesan data mulai dari input dataset hingga menghasilkan dataset seimbang yang siap digunakan pada tahap pelatihan model.



Gambar 2 Diagram Blok Augmentasi Dataset

Secara berurutan, sistem augmentasi dataset yang di tunjukan pada **Gambar 2** terdiri atas beberapa komponen utama, yaitu:

1. Input Dataset Histopatologi, berupa dataset awal dengan distribusi kelas tidak seimbang.
2. Analisis Distribusi Kelas, untuk menghitung jumlah citra pada setiap kelas.

3. Identifikasi Kelas Mayoritas dan Minoritas, guna menentukan kelas yang memerlukan augmentasi.
4. Modul Augmentasi Data, yang diterapkan pada kelas minoritas hingga jumlah data setara dengan kelas mayoritas.
5. Dataset Seimbang, sebagai keluaran dari proses augmentasi.
6. Preprocessing Dataset, untuk menyiapkan data sebelum tahap pelatihan model.

Proses ini memastikan bahwa dataset yang digunakan memiliki distribusi kelas yang seimbang, sehingga dapat mengurangi bias model dan meningkatkan performa klasifikasi.

3.2.3. Teknik Augmentasi Dataset

Augmentasi data pada kelas minoritas adalah strategi krusial dalam menangani imbalance data (ketidakseimbangan data). Tujuannya bukan sekadar memperbanyak jumlah, tetapi memperkaya variasi informasi agar model machine learning tidak hanya "menghafal" kelas mayoritas, tetapi juga mampu mengenali pola kelas minoritas dengan akurat. Berikut adalah pengembangan dari teknik-teknik augmentasi data tersebut:

1. Flip horizontal
2. Flip vertikal
3. Rotasi 90° searah jarum jam
4. Rotasi 90° berlawanan arah jarum jam
5. Rotasi 180°
6. Peningkatan saturasi sebesar 25%
7. Penurunan saturasi sebesar 25%

Teknik flipping dan rotasi digunakan karena struktur jaringan histopatologi tidak bergantung pada orientasi tertentu. Sementara itu, penyesuaian saturasi diterapkan untuk mensimulasikan variasi pewarnaan hematoxylin and eosin (H&E) yang umum terjadi pada citra histopatologi, sehingga meningkatkan ketahanan model terhadap variasi warna.

3.2.4. Pra-Pemrosesan Citra.

Setelah proses augmentasi, seluruh citra dikonversi ke dalam format grayscale. Konversi ini dilakukan karena metode GLCM bekerja berdasarkan intensitas keabuan dan

hubungan spasial antar piksel, sementara informasi warna memiliki kontribusi yang relatif kecil terhadap karakteristik tekstur jaringan.

Selain itu, konversi grayscale mengurangi kompleksitas data dari tiga kanal (RGB) menjadi satu kanal intensitas, sehingga menurunkan kebutuhan komputasi dan membantu model fokus pada pola tekstur yang relevan.

Dataset yang telah dipraproses kemudian dibagi menjadi data latih (training), data validasi (validation), dan data uji (testing) untuk memastikan kemampuan generalisasi model.

3.3. Ekstraksi Fitur, Klasifikasi, dan Alur Sistem.

3.3.1 Ekstraksi Fitur Tekstur Menggunakan Metode GLCM.

Ekstraksi fitur tekstur dilakukan menggunakan metode Gray Level Co-occurrence Matrix (GLCM) untuk menangkap karakteristik tekstur jaringan histopatologi berdasarkan hubungan spasial antar piksel. Fitur-fitur tekstur yang dihasilkan digunakan sebagai representasi pola mikrostruktur jaringan yang bersifat diskriminatif antar kelas kanker payudara.

3.3.2. Klasifikasi Menggunakan Metode EfficientNet

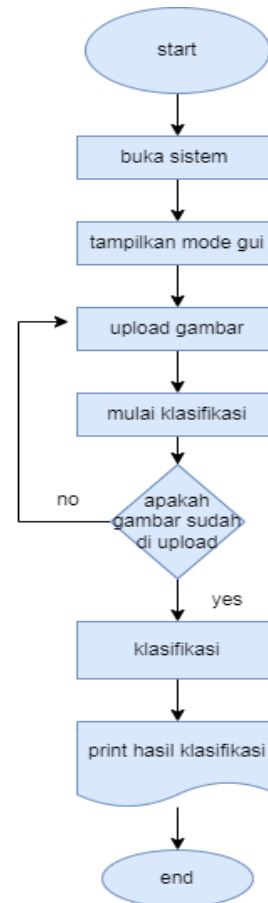
Proses klasifikasi citra dilakukan menggunakan arsitektur EfficientNet, yaitu model Convolutional Neural Network (CNN) yang menerapkan pendekatan compound scaling untuk menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara efisien. EfficientNet digunakan sebagai model utama karena mampu menghasilkan performa klasifikasi yang tinggi dengan jumlah parameter yang relatif lebih sedikit dibandingkan arsitektur CNN konvensional.

Fitur tekstur hasil ekstraksi GLCM dikombinasikan dengan pembelajaran fitur mendalam dari EfficientNet untuk meningkatkan kemampuan model dalam membedakan pola citra histopatologi kanker payudara.

3.3.3 Flowchart Sistem Klasifikasi.

Alur operasional sistem klasifikasi citra dijelaskan melalui flowchart sistem sebagaimana ditunjukkan pada **Gambar 3**. Flowchart ini menggambarkan urutan proses

mulai dari input citra oleh pengguna, pengecekan keberhasilan input, proses klasifikasi oleh sistem, hingga penampilan hasil klasifikasi. Flowchart sistem digunakan untuk menjelaskan mekanisme kerja sistem secara logis dan terstruktur, sehingga memudahkan pemahaman terhadap proses klasifikasi yang diimplementasikan.



Gambar 3 Flowcart System

Pada **Gambar 3** menunjukkan alur kerja system klasifikasi citra histopatologi kanker payudara berbasis metode GLCM dan EfficientNet yang diusulkan. Proses dimulai dari tahap input citra oleh pengguna, kemudian sistem melakukan pengecekan untuk memastikan bahwa citra telah berhasil dimuat. Setelah citra tervalidasi, sistem melanjutkan ke tahap klasifikasi dengan memanfaatkan model yang telah dilatih sebelumnya. Hasil klasifikasi selanjutnya ditampilkan sebagai keluaran sistem, dan proses berakhir setelah informasi kelas citra berhasil disajikan kepada pengguna.

3.3.4 Evaluasi Kinerja Model

Kinerja sistem klasifikasi dievaluasi menggunakan metrik kuantitatif berupa akurasi, presisi, recall, dan F1-score. Evaluasi dilakukan pada data uji untuk memperoleh gambaran objektif mengenai kemampuan model dalam mengklasifikasikan citra histopatologi kanker payudara. Hasil pengukuran setiap metrik tersebut selanjutnya dianalisis dan dibahas secara rinci pada bagian *Hasil dan Pembahasan* untuk menilai efektivitas pendekatan yang diusulkan.

4. HASIL DAN PEMBAHASAN

4.1. Pendahuluan

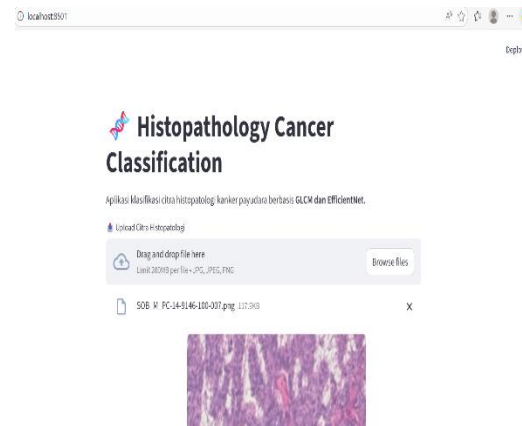
Hasil Bab ini menyajikan hasil implementasi dan evaluasi sistem klasifikasi citra histopatologi kanker payudara yang dikembangkan dengan memadukan Gray Level Co-Occurrence Matrix (GLCM) sebagai ekstraksi fitur tekstur dan EfficientNet sebagai model deep learning. Evaluasi difokuskan pada akurasi, presisi, recall, F1-score, serta stabilitas dan kemampuan generalisasi sistem dalam membedakan delapan kelas kanker payudara secara konsisten. Analisis dilakukan melalui grafik akurasi dan loss, confusion matrix, classification report, serta validasi kualitatif oleh dokter spesialis patologi anatomi.

4.2. Validasi Perancangan Sistem.

Sistem klasifikasi diimplementasikan sesuai rancangan pipeline pada Bab III. Tahapan sistem mencakup:

1. Pra-pemrosesan citra untuk meningkatkan kualitas dan konsistensi data masukan.
2. Ekstraksi fitur tekstur menggunakan GLCM dengan konfigurasi terbaik (256 fitur).
3. Ekstraksi fitur visual adaptif menggunakan arsitektur EfficientNet.
4. Integrasi fitur (feature-level fusion) sebelum klasifikasi akhir.

Implementasi ini direalisasikan dalam bentuk aplikasi operasional (**Gambar 4**), yang menunjukkan bahwa setiap tahapan dapat dijalankan secara terstruktur, saling terintegrasi, dan sesuai alur yang telah direncanakan. Hasil ini menegaskan bahwa desain sistem bersifat aplikatif dan dapat mendukung tujuan penelitian secara konsisten.



Gambar 4 Tampilan System

Pada **Gambar 4** membuktikan bahwa integrasi metode ekstraksi fitur klasik dengan pendekatan deep learning dapat diimplementasikan secara operasional. Seluruh tahapan mulai dari prapemrosesan, ekstraksi, hingga klasifikasi akhir berjalan secara terstruktur dan saling terintegrasi. Hal ini menegaskan bahwa desain sistem yang diusulkan bersifat aplikatif, konsisten, dan mampu menjawab tujuan penelitian secara efektif. Keberhasilan alur kerja ini menunjukkan bahwa sinergi antara karakteristik tekstur konvensional dan pembelajaran fitur tingkat tinggi mampu beroperasi secara *real-time* tanpa mengurangi akurasi. Selain itu, modularitas pada setiap tahapan sistem memudahkan pengembangan dan pemeliharaan lebih lanjut untuk aplikasi di lingkungan produksi sesungguhnya.

Metode GLCM dan EfficientNet merupakan variabel bebas utama. GLCM menangkap karakteristik tekstur orde-dua untuk merepresentasikan pola spasial piksel, sedangkan EfficientNet mempelajari fitur visual hierarkis secara adaptif. Integrasi kedua metode menghasilkan representasi citra yang lebih komprehensif dibandingkan metode tunggal. Stabilitas proses pelatihan, validasi, dan pengujian menunjukkan hubungan variabel bebas dengan performa sistem berjalan sesuai rancangan, sehingga rumusan masalah pertama penelitian dapat dijawab secara empiris.

4.3. Hasil Pelatihan dan Analisis Kinerja.


4.3.1. Metode GLCM

Model GLCM dievaluasi dengan variasi jumlah fitur tekstur: 64, 128, dan 256. Hasil menunjukkan bahwa penggunaan **256 fitur** memberikan performa terbaik, dengan akurasi pelatihan 66% dan akurasi validasi 74%.

Tabel 1 Hasil Perbandingan Berdasarkan Jumlah Fitur


Jumlah fitur	Akurasi pelatihan	Akurasi validasi
64	34%	42%
128	51%	66%
256	66%	74%

Diskusi Evaluasi metode GLCM dilakukan melalui analisis grafik akurasi dan loss selama proses pelatihan.



Gambar 5 Gambar Grafik Metode GLCM.

menunjukkan peningkatan kinerja model yang berlangsung secara bertahap dari epoch awal hingga akhir. Akurasi pelatihan meningkat dari 21% menjadi 66%, sedangkan akurasi validasi naik dari 32% hingga mencapai 74% pada epoch ke-30. Tren peningkatan yang stabil serta keselarasan antara kurva pelatihan dan validasi mengindikasikan bahwa model telah mencapai kondisi konvergen dan mampu mempelajari pola tekstur citra secara konsisten tanpa mengalami overfitting.




Gambar 6 Grafik Loss Metode GLCM Loss

Sementara itu, grafik loss pada **Gambar 6** memperlihatkan penurunan nilai loss yang sejalan dengan peningkatan akurasi. Nilai *train loss* menurun dari 2,22 menjadi 0,94, sedangkan *validation loss* turun dari 1,84 menjadi 0,77. Penurunan yang stabil dan minim fluktuasi menunjukkan proses pembelajaran yang efektif. Namun, akurasi yang masih terbatas mengindikasikan bahwa fitur tekstur GLCM belum sepenuhnya merepresentasikan kompleksitas citra histopatologi, sehingga diperlukan pendekatan lanjutan melalui metode hybrid dengan EfficientNet.

4.3.2. Metode EfficientNet

Subbab ini membahas hasil pelatihan dan evaluasi model klasifikasi citra histopatologi kanker payudara menggunakan arsitektur EfficientNet, yaitu model deep learning berbasis Convolutional Neural Network (CNN) dengan pendekatan compound scaling. Evaluasi difokuskan pada analisis grafik akurasi dan loss selama proses pelatihan serta pengujian hasil klasifikasi.


Model dilatih secara end-to-end menggunakan citra histopatologi tanpa fitur handcrafted, dengan skema pembagian data yang sama seperti metode sebelumnya. Pelatihan dilakukan hingga maksimum 30 epoch dan dilengkapi mekanisme early stopping untuk menghentikan proses secara otomatis ketika performa validasi tidak lagi meningkat.



Gambar 7 Grafik Akurasi Metode EfficientNet

Grafik akurasi pada **Gambar 7** menunjukkan peningkatan performa yang sangat cepat, dengan akurasi pelatihan melampaui 90% pada epoch ke-2 dan mencapai lebih dari 99%, sementara akurasi validasi stabil pada kisaran 97–98%. Proses

pelatihan berhenti pada epoch ke-21, menandakan model telah mencapai kondisi konvergen dan memiliki kemampuan generalisasi yang tinggi.




Gambar 8 Grafik Loss Metode EfficientNet.

Grafik loss pada **Gambar 8** memperlihatkan penurunan nilai loss yang tajam pada epoch awal, di mana training loss turun dari sekitar 1,5 menjadi di bawah 0,2 dalam empat epoch pertama, sementara validation loss tetap rendah dan stabil pada kisaran 0,06–0,1. Pola ini menegaskan bahwa EfficientNet mampu mempelajari karakteristik citra secara efektif tanpa mengalami overfitting.

4.3.3. Metode Hybrid GLCM dan EfficientNet.


Diskusi Subbab ini membahas hasil pelatihan dan evaluasi model klasifikasi citra histopatologi kanker payudara menggunakan pendekatan hybrid yang menggabungkan fitur tekstur Gray Level Co-occurrence Matrix (GLCM) dan fitur visual hasil ekstraksi otomatis dari EfficientNet. Integrasi kedua jenis fitur ini bertujuan untuk memanfaatkan informasi tekstur lokal dan representasi fitur hierarkis secara bersamaan guna meningkatkan kinerja klasifikasi.

Fitur tekstur GLCM dengan konfigurasi terbaik (256 fitur) digabungkan dengan fitur hasil ekstraksi EfficientNet, kemudian dilatih menggunakan skema pembagian data yang sama dengan metode sebelumnya untuk memastikan perbandingan yang objektif. Proses pelatihan dilakukan hingga maksimum 30 epoch dengan penerapan mekanisme early stopping untuk mencegah overfitting.



Gambar 9 Grafik Akurasi Metode Hybrid GLCM dan EfficientNet

Grafik akurasi pelatihan dan validasi yang ditunjukkan pada Gambar 9 memperlihatkan peningkatan performa yang stabil sejak epoch awal hingga mencapai kondisi konvergen. Akurasi validasi secara konsisten mengikuti pola akurasi pelatihan dan mencapai nilai mendekati 98% pada akhir iterasi. Selisih yang minimal antara kedua kurva tersebut mengindikasikan bahwa model hybrid memiliki kemampuan generalisasi yang sangat baik dalam mengenali citra histopatologi yang belum pernah dilihat sebelumnya.




Gambar 10 Grafik Loss Metode Hybrid GLCM dan EfficientNet

Grafik loss pada Gambar 10 menunjukkan penurunan nilai loss yang konsisten pada data pelatihan dan validasi sepanjang proses pelatihan. Meskipun model memulai pelatihan dengan nilai loss yang relatif tinggi, kurva loss menurun secara gradual hingga mencapai nilai di bawah 0,1 tanpa fluktuasi signifikan. Pola ini menegaskan bahwa integrasi fitur GLCM dan EfficientNet mampu menghasilkan pembelajaran yang stabil, meminimalkan kesalahan prediksi, serta mengurangi risiko overfitting hingga akhir proses pelatihan.

4.4. Hasil Pengujian Model terhadap Data Baru.

Subbab ini menyajikan hasil pengujian model klasifikasi citra histopatologi kanker payudara terhadap data uji yang tidak digunakan pada tahap pelatihan. Evaluasi dilakukan menggunakan confusion matrix untuk menilai kemampuan model dalam memetakan label prediksi terhadap label aktual. Pengujian dilakukan pada tiga pendekatan, yaitu metode GLCM, EfficientNet, dan metode hybrid GLCM–EfficientNet, guna membandingkan kinerja klasifikasi masing-masing model secara kuantitatif.


4.4.1. Metode GLCM.



Gambar 11 Convusion Matrix Metode GLCM.

Hasil pengujian metode GLCM yang divisualisasikan pada Gambar 11 menunjukkan bahwa model mampu mengklasifikasikan sebagian besar citra dengan benar, ditandai oleh dominasi nilai pada diagonal utama. Kelas *tubular adenoma* dan *adenosis* memperoleh jumlah prediksi benar tertinggi. Namun, masih ditemukan kesalahan klasifikasi pada beberapa kelas dengan karakteristik tekstur yang mirip, seperti *fibroadenoma* yang keliru diprediksi sebagai *phyllodes tumor* serta *ductal carcinoma* yang tertukar dengan *adenosis*. Temuan ini mengindikasikan bahwa meskipun GLCM efektif dalam menangkap informasi tekstur, keterbatasan fitur handcrafted masih memengaruhi ketelitian pemisahan antar kelas tertentu.

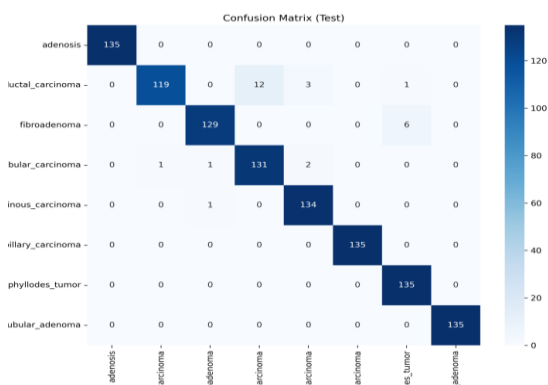
4.4.2. Metode EfficientNet.



Gambar 12 Convusion Matrix Metode EfficientNet.

Confusion matrix hasil pengujian EfficientNet pada Gambar 12 memperlihatkan performa klasifikasi yang sangat tinggi dan stabil. Hampir seluruh data uji terklasifikasi dengan benar, dengan beberapa kelas seperti *adenosis*, *papillary carcinoma*, dan *phyllodes tumor* mencapai hasil sempurna tanpa kesalahan prediksi. Kesalahan klasifikasi hanya terjadi dalam jumlah sangat terbatas, misalnya pada sebagian kecil citra *ductal carcinoma* yang diprediksi sebagai *lobular carcinoma*, yang kemungkinan disebabkan oleh kemiripan morfologi jaringan. Secara keseluruhan, EfficientNet menunjukkan kemampuan generalisasi yang sangat baik pada data baru.

4.4.3. Metode Hybrid GLCM dan EfficientNet.



Gambar 13 Convusion Matrix Hybrid GLCM dan Metode EfficientNet

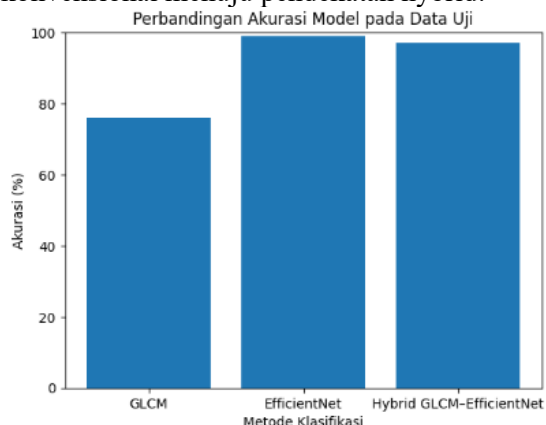
Performa terbaik ditunjukkan oleh metode hybrid sebagaimana terlihat pada confusion matrix di Gambar 13. Hampir

seluruh sampel uji pada setiap kelas berhasil diklasifikasikan dengan tepat, dengan dominasi kuat pada diagonal utama. Beberapa kelas bahkan mencapai tingkat klasifikasi sempurna. Hasil ini menegaskan bahwa integrasi fitur tekstur GLCM dan fitur deep learning EfficientNet menghasilkan representasi data yang lebih komprehensif, sehingga meningkatkan kemampuan model dalam membedakan kelas dengan kemiripan visual tinggi dibandingkan metode tunggal.

4.5. Pembahasan Perbandingan Kinerja Model.

Subbab ini membahas perbedaan kinerja sistem klasifikasi citra histopatologi kanker payudara berdasarkan hasil pengujian pada data baru yang telah dipaparkan pada Subbab 4.4. Analisis difokuskan pada perbandingan kemampuan klasifikasi antara metode GLCM, EfficientNet, dan metode hybrid GLCM–EfficientNet, dengan meninjau tingkat ketepatan prediksi serta pola kesalahan klasifikasi yang ditunjukkan melalui confusion matrix.

Untuk memberikan gambaran kuantitatif yang lebih jelas mengenai perbedaan kinerja antar metode, perbandingan hasil pengujian disajikan dalam bentuk grafik pada **Gambar 14**. Grafik tersebut menampilkan capaian performa masing-masing metode secara komparatif, sehingga memudahkan interpretasi peningkatan kinerja dari pendekatan konvensional menuju pendekatan hybrid.



Gambar 14 Grafik Perbandingan Model.

Gambar 32 menunjukkan perbandingan akurasi ketiga metode klasifikasi pada data uji, yaitu GLCM, EfficientNet, dan metode hybrid GLCM–EfficientNet. Terlihat bahwa metode

GLCM menghasilkan akurasi terendah, sedangkan EfficientNet mencapai akurasi tertinggi. Metode hybrid menunjukkan performa yang sangat kompetitif dengan akurasi mendekati EfficientNet murni.

Peningkatan kinerja pada metode hybrid mengindikasikan bahwa penggabungan fitur tekstur GLCM dan fitur visual hasil ekstraksi EfficientNet mampu menghasilkan representasi citra yang lebih informatif dibandingkan penggunaan fitur tunggal. Grafik ini memperkuat hasil analisis confusion matrix pada Subbab 4.4, sekaligus menegaskan keunggulan pendekatan hybrid dalam meningkatkan stabilitas dan ketepatan klasifikasi citra histopatologi kanker payudara. Peningkatan performa metode hybrid menunjukkan bahwa fusi fitur tekstur orde-dua dan fitur hierarkis CNN menghasilkan representasi citra yang lebih diskriminatif, khususnya pada kelas dengan kemiripan morfologi tinggi.

5. KESIMPULAN

Sistem klasifikasi citra histopatologi kanker payudara berhasil dirancang menggunakan kombinasi metode GLCM dan arsitektur EfficientNet.

Berdasarkan hasil pengujian, metode GLCM memperoleh akurasi sebesar 74%, metode EfficientNet memperoleh akurasi tertinggi sebesar 99%, sedangkan metode hybrid GLCM–EfficientNet memperoleh akurasi sebesar 98%. Hasil tersebut menunjukkan bahwa pendekatan deep learning meningkatkan akurasi sebesar 22% dibandingkan metode tekstur klasik, sementara metode hybrid memberikan peningkatan sebesar 21% dibandingkan GLCM, meskipun sedikit lebih rendah 1% dibandingkan EfficientNet murni. Dengan demikian, arsitektur EfficientNet menunjukkan performa paling optimal dalam klasifikasi jenis kanker payudara.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Dosen Pembimbing yang sudah mendukung penul dalam proses penelitian ini.

DAFTAR PUSTAKA

- [1] World Health Organization, "Breast cancer," World Health Organization, Fact Sheet, 2022. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/breast-cancer>.
- [2] N. T. R. Adiningrum, R. Rianti, and C. Priyanto, "RANCANG BANGUN APLIKASI PREDIKSI KANKER PAYUDARA DENGAN PENDEKATAN MACHINE LEARNING," *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 3s1, Sep. 2023, doi: 10.23960/jitet.v11i3s1.3351.
- [3] F. A. Kusuma, "Pemodelan Klasifikasi Anemia Aplastik Menggunakan Teknik Oversampling Dan K-Nearest Neighbors," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, 2024, doi: 10.23960/jitet.v12i3.4326.
- [4] R. A. B. K. -, B. I. -, and A. K. -, "KLASIFIKASI PENYAKIT KULIT WAJAH MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK EFFICIENTNET-B3," *J. Inform. dan Tek. Elektro Terap.*, vol. 14, no. 1, Jan. 2026, doi: 10.23960/jitet.v14i1.8721.
- [5] A. H. Farhan and M. Y. Kamil, "Texture Analysis of Breast Cancer via LBP, HOG, and GLCM techniques," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 928, no. 7, 2020, doi: 10.1088/1757-899X/928/7/072098.
- [6] M. W. Purbandanu, R. Yanuarta, and A. Kurniawan, "Optimization of Skin Cancer Detection to Improve Accuracy with the Application of Efficient Convolutional Neural Network and EfficientNetB2 Models," *J. Intell. Comput. Heal. Informatics*, vol. 5, no. 2, pp. 43–50, 2024, doi: 10.26714/jichi.v5i2.14338.
- [7] Erin Eka Citra, S. Mutmainah, and B. Hermanto, "Breast Cancer Detection Using EfficientNetV2 Variants and Data Augmentation: A Comparative Study," *J. Komputasi*, vol. 13, no. 1, pp. 13–24, 2025, doi: 10.23960/komputasi.v13i1.281.
- [8] M. Wei *et al.*, "A Benign and Malignant Breast Tumor Classification Method via Efficiently Combining Texture and Morphological Features on Ultrasound Images," *Comput. Math. Methods Med.*, vol. 2020, 2020, doi: 10.1155/2020/5894010.
- [9] F. Liantoni, A. Santoso, M. Munsarif, A. Azhar, and R. J. Rifa'i, "PERBAIKAN KONTRAS CITRA MAMMOGRAM PADA KLASIFIKASI KANKER PAYUDARA BERDASARKAN FITUR GRAY-LEVEL CO-OCCURRENCE MATRIX," *Sintech Journal*, vol. 3, no. 1, pp. 46–51, 2020, doi: 10.31598/sintechjournal.v3i1.528.
- [10] M. Kabir, F. Unal, T. C. Akinci, A. A. Martinez-Morales, and S. Ekici, "Revealing GLCM Metric Variations across a Plant Disease Dataset: A Comprehensive Examination and Future Prospects for Enhanced Deep Learning Applications," *Electron.*, vol. 13, no. 12, 2024, doi: 10.3390/electronics13122299.
- [11] A. Algiffary and T. Sutabri, "Indonesian Journal of Computer Science," *Indones. J. Comput. Sci.*, vol. 12, no. 2, pp. 284–301, 2023, [Online]. Available: <http://ijcs.stmikindonesia.ac.id/ijcs/index.php/ijcs/article/view/3135>
- [12] D. Tellez *et al.*, "Quantifying the effects of data augmentation and stain color normalization in convolutional neural networks for computational pathology," *Med. Image Anal.*, vol. 58, 2019, doi: 10.1016/j.media.2019.101544.
- [13] D. Tellez *et al.*, "Quantifying the effects of data augmentation and stain color normalization in convolutional neural networks for computational pathology," *Med. Image Anal.*, vol. 58, 2019, doi: 10.1016/j.media.2019.101544.
- [14] M. Azmoodeh-Kalati, H. Shabani, M. S. Maghareh, Z. Barzegar, and R. Lashgari, "Leveraging an ensemble of EfficientNetV1 and EfficientNetV2 models for classification and interpretation of breast cancer histopathology images," *Sci. Rep.*, vol. 15, no. 1, pp. 1–25, 2025, doi: 10.1038/s41598-025-06853-6.
- [15] M. Pradeepa, B. Sharmila, and M. Nirmala, "A hybrid deep learning model EfficientNet with GRU for breast cancer detection from histopathology images," *Sci. Rep.*, vol. 15, no. 1, pp. 1–24, 2025, doi: 10.1038/s41598-025-00930-6.
- [16] M. Al-Jabbar, M. Alshahrani, E. M. Senan, and I. A. Ahmed, "Analyzing Histological Images Using Hybrid Techniques for Early Detection of Multi-Class Breast Cancer Based on Fusion Features of CNN and Handcrafted," *Diagnostics*, vol. 13, no. 10, p. 1753, May 2023, doi: 10.3390/diagnostics13101753.