

Klasifikasi Citra *CT Scan* Kanker Paru-Paru Menggunakan Pendekatan *Deep Learning*

Anggi Mulya*, Rice Novita

Fakultas Sains dan Teknologi, Sistem Informasi, Universitas Islam Sultan Syarif Kasim Riau, Pekanbaru, Indonesia

Email: ^{1,*}12150312142@students.uin-suska.ac.id, ²rice.novita@uin-suska.ac.id

Email Penulis Korespondensi: 12150312142@students.uin-suska.ac.id

Submitted: 26/12/2024; Accepted: 26/02/2025; Published: 01/03/2025

Abstrak—Penelitian ini bertujuan mengembangkan model *deep learning* yang handal untuk mengklasifikasi citra *CT Scan* kanker paru-paru. Penelitian ini memiliki keunggulan dengan mengevaluasi kinerja beberapa arsitektur *Convolutional Neural Networks* (CNN) termasuk DenseNet121, InceptionResNetV2, InceptionV3, dan ResNet152V2 untuk membandingkan performanya dalam akurasi klasifikasi. Dataset terdiri dari 1.561 citra *CT Scan* yang diperoleh dari Kaggle, dataset tersebut dikategorikan menjadi kanker ganas, kanker jinak, dan normal. Melalui kombinasi teknik *preprocessing* data yang inovatif, seperti augmentasi dengan rotasi acak dan normalisasi, pembagian dataset menggunakan metode *hold-out* dengan rasio 70:30, 80:20, dan 90:10, serta pelatihan model menggunakan optimisasi Adam dan SGDM, peneliti berhasil mencapai akurasi klasifikasi yang sangat tinggi. Hasil evaluasi menunjukkan bahwa InceptionV3 dengan optimisasi SGDM pada rasio 90:10 mencapai performa yang sangat baik dengan akurasi 99,38% sedangkan InceptionResNetV2 dengan optimisasi Adam pada *hold-out* 80:20 menunjukkan performa tertinggi, dengan perolehan akurasi sebesar 99,40%. Hasil yang menjanjikan ini mengindikasikan potensi besar dalam mendukung penemuan dini kanker paru-paru, sehingga dapat meningkatkan akurasi diagnosis dan peluang kesembuhan pasien. Penelitian ini membuka peluang untuk pengembangan lebih lanjut, seperti penerapan *fine-tuning*, *ensemble learning* atau integrasi dengan sistem pendukung keputusan klinis untuk aplikasi di dunia medis.

Kata Kunci: CNN; CT Scan; Deep Learning; Klasifikasi; Kanker Paru-Paru

Abstract—This research aims to develop a reliable deep learning model for classifying CT-scan images of lung cancer. This research has the advantage of evaluating the performance of several Convolutional Neural Networks (CNN) architectures including DenseNet121, InceptionResNetV2, InceptionV3 and ResNet152V2 to compare their performance in classification accuracy. The dataset consists of 1,561 CT scan images obtained from Kaggle and the dataset is categorized into malignant cancer, benign cancer and normal. Through a combination of innovative data pre-processing techniques, such as augmentation with random rotation and normalization, division of the dataset using the hold-out method with ratios of 70:30, 80:20, and 90:10, and model training using Adam's optimizer and SGDM, researchers achieved very high classification accuracy. The evaluation results showed that InceptionV3 with SGDM optimizer at 90:10 ratio achieved performed very well with an accuracy of 99.38% while InceptionResNetV2 with Adam optimizer at 80:20 hold-out the highest performance, with an accuracy of 99.40%. These promising results indicate great potential in supporting the early discovery of lung cancer, thereby improving the accuracy of diagnosis and the chances of patient recovery. This research opens up opportunities for further development, such as the application of fine-tuning, ensemble learning, or integration with clinical decision support systems for medical applications.

Keywords: Classification; CNN; CT Scan; Deep Learning; Lung Cancer

1. PENDAHULUAN

Kanker paru-paru merupakan salah satu penyakit dengan angka insidensi dan mortalitas tertinggi di dunia bahkan menyebabkan lebih banyak kematian dibandingkan kanker kolorektum, hati, dan payudara. Berdasarkan laporan dari GLOBOCAN pada tahun 2022, kanker paru menyumbang sekitar 2.480.301 kasus baru kanker paru-paru dan 1.817.172 kematian akibat kanker paru-paru di seluruh dunia. Kanker paru-paru menempati urutan pertama sebagai penyebab kematian akibat kanker pada pria dan urutan kedua pada wanita [1]. Menemukan kanker paru-paru pada stadium awal adalah satu-satunya metode untuk penyembuhannya, salah satu metode yang paling umum digunakan dalam penemuan dini kanker paru-paru adalah dengan menggunakan *Computerized Tomography Scan* (CT Scan) [2].

CT Scan dipilih karena dapat memberikan gambaran yang lebih rinci dan akurat dibandingkan dengan metode lain seperti X-Ray, serta memungkinkan identifikasi nodul atau massa kecil. Namun, interpretasi citra CT Scan memerlukan keahlian khusus, karena tanda-tanda abnormal seperti nodul atau massa pada paru-paru sering kali sulit dikenali, terutama pada tahap awal perkembangan kanker [3], [4], [5]. Dalam beberapa tahun terakhir, metode *deep learning* telah menunjukkan hasil yang menjanjikan dalam berbagai aplikasi, termasuk dalam analisis citra medis [5].

Pada bidang medis, *deep learning* digunakan untuk mendeteksi masalah jantung, analisis gambar tumor, mendiagnosis kanker, dan banyak aplikasi lainnya [6]. Pendekatan *deep learning* memungkinkan pengembangan model yang dapat secara otomatis mempelajari fitur-fitur kompleks dari data gambar dan menggunakannya untuk melakukan tugas yang diberikan, misalnya klasifikasi, segmentasi, dll [7], [8]. *Deep learning* populer karena kemampuan ekstraksi fitur otomatisnya dan diterapkan di berbagai bidang seperti *Convolutional Neural Network* (CNN) [8].

CNN merupakan model *deep learning* yang paling banyak digunakan dalam pembelajaran fitur untuk klasifikasi dan pengenalan gambar berskala besar [9]. Secara umum, model CNN terdiri dari *convolutional layer*, *pooling layer*, dan *fully connected layer*. Lapisan-lapisan ini ditumpuk untuk membentuk arsitektur yang dalam untuk ekstraksi fitur otomatis pada data sensor mentah [10]. Untuk meningkatkan kinerja algoritma CNN dalam klasifikasi

citra *CT Scan* kanker paru-paru peneliti menggunakan beberapa model arsitektur yang sudah ada sebelumnya yaitu DenseNet121, InceptionV3, ResNet152V2 dan InceptionResNetV2.

DenseNet121 berfungsi meningkatkan kecepatan informasi melalui jaringan dan mengurangi masalah gradien yang hilang. DenseNet121 juga memiliki konektivitas yang padat serta memiliki efek yang teratur dan mengurangi *overfitting* pada saat pelatihan [11]. Selain itu, InceptionV3, yang menggunakan filter dengan berbagai ukuran untuk menangkap fitur pada berbagai skala yang sangat berguna dalam pengolahan citra medis yang kompleks [12]. Arsitektur lain yang juga banyak digunakan adalah model InceptionResNetV2 memanfaatkan koneksi residual ke modul inception setelah implementasi stem. Hal ini memungkinkan InceptionResNetV2 untuk mencapai akurasi yang lebih tinggi dalam jangka waktu yang lebih singkat [13]. Di sisi lain, ResNet152V2 mengatasi masalah degradasi performa jaringan dengan memperkenalkan koneksi residual yang memungkinkan pelatihan jaringan yang lebih dalam tanpa kehilangan akurasi dan meningkatkan ekstraksi informasi dari data *input* [9], [14].

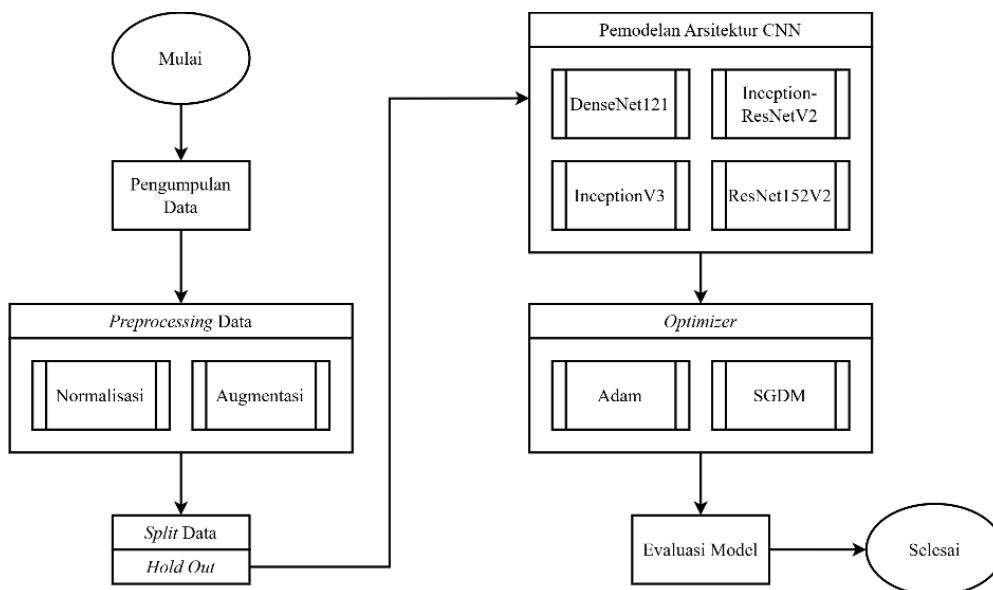
Pada penelitian yang dilakukan oleh Pattanaik et al. (2022), model DenseNet121 digunakan untuk klasifikasi kanker payudara, model ini mencapai akurasi pengujian sebesar 98,84%. Selanjutnya, Mujahid et al. (2022) menggunakan InceptionV3 untuk klasifikasi pneumonia dari citra *X-Ray* mencapai akurasi sebesar 99,29% [15]. Kemudian, penelitian oleh Kalkan et al. (2024) menerapkan ResNet152V2 untuk analisis perbandingan metode *deep learning* pada citra *CT* untuk spesifikasi kanker paru-paru, menghasilkan akurasi sebesar 98.29% [16]. Lalu, penelitian oleh Prasanthi et al. (2024) menggunakan InceptionResNetV2 untuk peningkatan kategorisasi tumor otak menggunakan *deep learning*, dengan akurasi mencapai 94,79% [17].

Penelitian ini memiliki keunggulan dengan mengevaluasi kinerja beberapa arsitektur CNN yaitu DenseNet121, InceptionResNetV2, InceptionV3 dan ResNet152V2 dengan pembagian dataset menggunakan metode *hold-out* dengan rasio 70:30, 80:20 dan 90:10, serta pelatihan model menggunakan optimisasi Adam dan SGDM untuk menentukan performa terbaik dalam klasifikasi citra *CT Scan* kanker paru-paru. Melalui penggunaan dataset citra *CT Scan* yang besar dan teknik *deep learning*, penelitian ini diharapkan dapat menghasilkan model yang mampu mengklasifikasi kanker paru-paru dengan performa akurasi yang sangat baik, sehingga dapat mendukung penemuan dini kanker paru-paru.

2. METODOLOGI PENELITIAN

2.1 Metodologi Penelitian

Adapun tahapan penelitian ini dimulai dengan pengumpulan dataset citra *CT Scan* kanker paru-paru, diikuti *preprocessing* data dengan normalisasi dan augmentasi data. Data kemudian dibagi menggunakan teknik *hold-out* 70:30, 80:20 dan 90:10 untuk pelatihan, validasi, dan pengujian. Beberapa arsitektur CNN seperti DenseNet121, InceptionV3, InceptionResNetV2 dan ResNet152V2 diterapkan, lalu dioptimalkan menggunakan Adam dan SGDM. Tahapan diakhiri dengan evaluasi model untuk menilai performa akurasi klasifikasi. Alur metodologi penelitian dapat dilihat pada Gambar 1.



Gambar 1. Metodologi Penelitian

2.2 Pengumpulan Data

Data yang digunakan dalam penelitian ini terdiri dari citra *CT Scan* kanker paru-paru yang diperoleh dari situs *Kaggle*. Dataset ini mencakup tiga kategori label yaitu kanker ganas sebanyak 561 gambar, kanker jinak sebanyak 480 gambar dan normal sebanyak 520 gambar sehingga didapatkan gambar total sebanyak 1561 gambar.

2.3 Preprocessing Data

Setelah data mentah diperoleh, langkah berikutnya adalah melakukan *preprocessing*, yang meliputi normalisasi dan augmentasi. Data mentah awalnya memiliki ukuran dan bentuk yang tidak seragam, sehingga perlu disesuaikan agar komputasi berjalan lebih efisien dan mempermudah pengujian model. Augmentasi pada data pelatihan mencakup rotasi acak hingga 45 derajat, normalisasi nilai piksel gambar ke rentang 0-1 dengan membaginya dengan 255, serta flip gambar secara horizontal dan vertikal. Area kosong yang muncul diisi dengan nilai piksel terdekat. Untuk data uji, augmentasi tidak diterapkan hanya dilakukan normalisasi skala nilai piksel. Selain itu, pada tahap *preprocessing* ukuran *batch* juga ditentukan untuk mengatur jumlah sampel gambar yang dihasilkan oleh generator selama proses pelatihan.

2.4 Split Data


Tahap selanjutnya *split* data yaitu membagi dataset menjadi data latih, data validasi dan data uji yang merupakan langkah krusial sebelum pengujian model. Dalam penelitian ini digunakan metode *hold-out* yang merupakan salah satu teknik evaluasi model pembelajaran mesin paling populer. Teknik ini membagi dataset menjadi dua bagian yaitu data pelatihan dan data pengujian. Pada penelitian ini rasio yang akan digunakan adalah 70:30, 80:20, dan 90:10. 70%, 80%, dan 90% akan digunakan untuk data latih dan data validasi, sedangkan 30%, 20%, dan 10% sisanya untuk data uji. Metode *hold-out* dipilih karena kesederhanaannya dan kemampuannya menghasilkan estimasi model dengan bias yang lebih rendah dibandingkan teknik lain. Data yang telah dibagi ditempatkan dalam direktori terpisah untuk memudahkan pengolahan lebih lanjut. Pembagian ini bertujuan memastikan bahwa model dapat dievaluasi secara akurat dan memiliki kemampuan generalisasi yang baik terhadap data baru.

2.5 Pemodelan Arsitektur CNN

Pada tahap ini, penelitian fokus pada pengujian model menggunakan arsitektur CNN untuk klasifikasi citra *CT Scan* kanker paru-paru. Model CNN terdiri dari berbagai lapisan yang bekerja secara berurutan untuk mengidentifikasi dan mengekstrak fitur penting dari citra. Arsitektur CNN yang diterapkan dalam penelitian ini termasuk DenseNet121, InceptionResNetV2, InceptionV3 dan ResNet152V2. Tujuannya adalah untuk membandingkan kinerja masing-masing arsitektur dalam hal akurasi dan efektivitas. Keseluruhan pendekatan ini dirancang untuk mengoptimalkan ekstraksi fitur dan klasifikasi citra dengan akurasi yang tinggi, menjadikannya metode yang sangat efektif dalam penelitian klasifikasi citra.

2.6 DenseNet121

Densely Connected Convolutional Networks (DenseNet) merupakan arsitektur pembelajaran mendalam yang telah menunjukkan keefektifan dalam berbagai tugas yang berhubungan dengan gambar termasuk analisis citra medis [18]. DenseNet adalah pengekstrak fitur gambar yang menggunakan koneksi padat di semua lapisan konvolusi. Dalam DenseNet, setiap lapisan digabungkan dengan semua lapisan sebelumnya dalam dimensi saluran dan digunakan sebagai *input* lapisan berikutnya [9]. Varian DenseNet meliputi DenseNet-121, DenseNet-169, dan DenseNet-201 [19]. DenseNet121 digunakan sebagai salah satu model untuk merangkai ke dalam model yang diusulkan, di mana 121 adalah jumlah total lapisan yang ada dalam arsitektur [20].




Gambar 2. DenseNet121

Seperti yang ditunjukkan pada Gambar 2, DenseNet121 memiliki empat blok dense dan lapisan transisi di antara setiap blok dense. Setiap blok dense berisi beberapa *convolutional layer* dan setiap *transition layer* berisi normalisasi *batch*, *pooling layer* dan *convolutional layer*. Dalam model ini, *global average pooling layer* yang merupakan lapisan terakhir dari DenseNet121, menghasilkan fitur dari gambar *input*. Kemudian, fitur yang diperoleh dioperasikan oleh pengklasifikasi untuk melakukan prediksi akhir.

2.7 InceptionResNetV2

InceptionResNetV2 adalah arsitektur CNN yang mengambil keuntungan dari blok inisiasi dan blok residual, sehingga memperkenalkan dan memanfaatkan konsep blok inisiasi residual [21]. Jaringan ini menerima *input* dengan ukuran 299×299 , terdiri dari 164 lapisan, dan telah dilatih sebelumnya pada dataset *ImageNet* yang mampu mengklasifikasikan gambar ke dalam 1000 kategori [12]. InceptionResNetV2 terdiri dari batang yang sama dengan InceptionV3 dan blok residual yang sama dengan ResNet. Model InceptionResNetV2 memanfaatkan koneksi residual

ke modul inception setelah implementasi stem. Hal ini memungkinkan InceptionResNetV2 untuk mencapai akurasi yang lebih tinggi dalam jangka waktu yang lebih singkat [13].

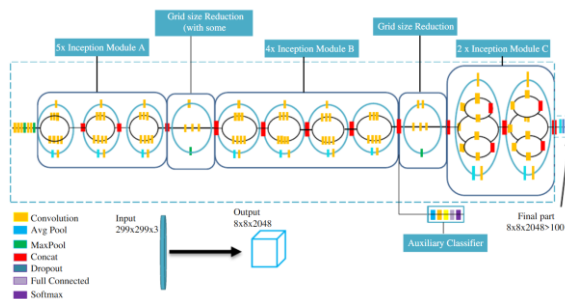


Gambar 3. InceptionResNetV2

Gambar 3 mengilustrasikan arsitektur jaringan dari InceptionResNetV2. Seperti yang dapat dilihat, InceptionResNet152V2 terdiri dari blok stem, blok InceptionResNet152 A, B dan C, *dropout layer* berfungsi untuk menjatuhkan bobot secara acak (membuat nilai filter sama dengan 0) untuk mencegah *overfitting*, *fully connected layer* dan *softmax layer* lalu menghasilkan klasifikasi. Keuntungan utama model ini berasal dari perluasan blok InceptionResNet A, B, dan C. Penyesuaian ini bertujuan untuk meningkatkan kinerja model, terutama ketika bekerja dengan dataset yang lebih kecil. Dengan menerapkan modifikasi ini, model ini memiliki potensi untuk meningkatkan akurasi, beradaptasi lebih baik pada dataset dengan sampel terbatas dan mengurangi waktu pelatihan.

2.8 InceptionV3

Arsitektur InceptionV3 dikembangkan oleh Google yang merupakan versi ketiga dari Inception [22]. InceptionV3 dapat menguraikan *convolutional layer* yang lebih besar menjadi lapisan yang lebih kecil, sehingga mengurangi kumpulan parameter dan cocok untuk dataset yang lebih kecil [23]. InceptionV3 memiliki kinerja klasifikasi gambar yang tinggi dan diintegrasikan oleh *convolution layers*, *avg pool*, *maxpool*, *concat*, *dropout*, *fully connected layers* dan *softmax* [24].




Gambar 4. InceptionV3

Gambar 4 menunjukkan arsitektur InceptionV3 yang terdiri dari satu blok *input*, tiga blok Modul Inception A, B dan C, dua blok pengurangan ukuran jaringan, satu blok pengklasifikasi tambahan, dan satu blok *output*. Jaringan ini terdiri dari 42 lapisan dalam yang menerima *input* data spasial 299 X 299 X 3 pada blok masukan[25]. Modul Inception adalah konsep baru dan populer karena konvolusi yang lebih kecil, yang menjelaskan pengurangan jumlah parameter. Model InceptionV3 mengumpulkan lebih banyak informasi tanpa mempengaruhi kecepatan komputasi berkat kedalamannya dan berbagai ukuran kernel yang digunakan dalam operasi konvolusi [26].

2.9 ResNet152V2

Residual Neural Network(ResNet) adalah jenis jaringan saraf yang populer yang secara efektif mengatasi masalah degradasi dan meningkatkan ekstraksi informasi dari data *input* [9], [14]. Hal ini dicapai dengan memanfaatkan modul pemetaan identitas, yang menggabungkan koneksi lompatan atau jalan pintas untuk melompati lapisan dalam jaringan [27]. Hal ini memungkinkan ResNet untuk mencapai kedalaman yang luar biasa hingga 152 lapisan [14].



Gambar 5. ResNet152V2

Seperti yang ditunjukkan pada Gambar 5 arsitektur model terdiri dari model ResNet152V2 yang diikuti dengan pembentukan kembali *reshape layer*, *flatten layer*, *dense layer* dengan 128 neuron, *dropout layer* dan akhirnya *dense layer* dengan fungsi aktivasi *softmax* untuk mengklasifikasikan gambar ke dalam kelas yang sesuai [28].

2.10 Optimisasi

Optimisasi berperan penting dalam pelatihan CNN untuk mencapai konvergensi optimal dengan menyesuaikan bobot model. Penelitian ini menggunakan Adam dan SGDM, di mana Adam menyesuaikan laju pembelajaran secara adaptif, sementara SGDM mempercepat konvergensi dengan momentum. Pemilihan optimisasi yang tepat membantu meningkatkan akurasi dan efisiensi pelatihan model.

2.10 Evaluasi Model

Evaluasi model adalah tahap penting dalam penelitian klasifikasi citra untuk menilai efektivitas model pada data baru. *Confusion matrix* digunakan untuk menganalisis kesalahan dan mengidentifikasi pola tertentu guna meningkatkan performa. Metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-Score* memberikan gambaran komprehensif tentang kinerja model. Akurasi menunjukkan tingkat klasifikasi yang benar, presisi menilai kualitas klasifikasi positif, *recall* mengukur deteksi kasus positif dan *F1-Score* menyeimbangkan presisi serta *recall*. Parameter kinerja ini dapat dijelaskan menggunakan rumus-rumus berikut [29].

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \tag{1}$$

$$\text{Presisi} = \frac{TP}{TP+FP} \tag{2}$$

$$\text{Recall} = \frac{TP}{TP+FN} \tag{3}$$


$$F1\text{-Score} = 2 + \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \tag{4}$$

Struktur dasar *confusion matrix* untuk kasus klasifikasi biner terdiri dari empat komponen utama yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP) dan *False Negative* (FN). Komponen-komponen ini menjadi dasar perhitungan berbagai metrik evaluasi yang lebih kompleks [30].

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Pada penelitian ini, Data yang digunakan dalam penelitian ini terdiri dari citra *CT Scan* kanker paru-paru yang diperoleh dari situs Kaggle. Visualisasi gambar dataset yang digunakan dalam penelitian ini dapat dilihat pada Gambar 6.



Gambar 6. Visualisasi Data

Tabel 1. Data Pakai


NO	KELAS	JUMLAH DATA
1	Kanker Ganas	561
2	Kanker Jinak	480
3	Normal	520
TOTAL		1561

Tabel 1 menunjukkan jumlah data yang terbagi ke dalam tiga kelas, yaitu kanker ganas, kanker jinak, dan normal. Kanker ganas memiliki jumlah data sebanyak 561 data gambar, kanker jinak memiliki 480 data gambar, dan normal mencatat sebanyak 520 data gambar. Secara keseluruhan total jumlah data gambar adalah 1.561.

3.2 Preprocessing Data

Tahap selanjutnya adalah *preprocessing* data yang melibatkan dua proses utama, yaitu normalisasi dan augmentasi gambar. Dalam proses normalisasi, nilai piksel gambar diubah dari rentang 0-255 menjadi rentang 0-1 dengan tujuan

agar setiap piksel memiliki distribusi data yang seragam. Selanjutnya, proses augmentasi dalam penelitian ini bertujuan untuk menambah variasi data dengan menerapkan transformasi seperti rotasi gambar sebesar 45° dan membalik gambar secara horizontal. Untuk deviasi acak pada gambar, ditentukan sudut geser hingga 15%, memperbesar gambar acak hingga 15%, membalik gambar secara vertikal dan horizontal, serta mengisi piksel kosong menggunakan nilai piksel terdekat. Augmentasi ini diterapkan pada citra yang digunakan dalam deteksi kanker paru-paru. Visualisasi citra yang telah diputar 45° ditampilkan pada Gambar 7.



Gambar 7. Hasil Augmentasi

3.3 Pembagian Data

Pembagian data terdiri dari tiga kategori yaitu data latih, data validasi, dan data uji. Data latih digunakan untuk melatih model agar mampu mengenali kanker paru-paru, sementara data validasi digunakan untuk mengevaluasi performa model selama proses pelatihan, biasanya pada akhir setiap epoch. Data uji adalah kumpulan data yang digunakan untuk mengevaluasi kinerja akhir model setelah proses pelatihan selesai. Data ini tidak digunakan selama pelatihan atau validasi, sehingga benar-benar baru bagi model. Data ini membantu memastikan bahwa model tidak hanya belajar dari data latih tetapi juga mampu bekerja pada data yang belum pernah dilihat. Pembagian data dilakukan dengan teknik *hold-out* dengan rasio 70:10, 80:20 dan 90:10, di mana sebagian besar dari data digunakan untuk pelatihan dan sisanya untuk pengujian. Selain itu, data pelatihan dibagi lagi menjadi data latih dan data validasi dengan rasio yang ditetapkan, yaitu sebagian besar untuk latih dan sisanya untuk validasi. Distribusi pembagian data dengan teknik *hold-out* dapat dilihat pada Tabel 2.

Tabel 2. Distribusi Pembagian Data

Hold-Out	KELAS	Data Latih	Data Validasi	Data Uji
70:30	Kanker Ganas	274	118	169
	Kanker Jinak	235	101	144
	Normal	254	110	156
80:20	Kanker Ganas	358	90	113
	Kanker Jinak	307	77	96
	Normal	332	84	104
90:10	Kanker Ganas	453	52	57
	Kanker Jinak	388	44	48
	Normal	421	47	52

3.4 Pemodelan Arsitektur CNN

Data dilatih dengan pemodelan CNN menggunakan Keras TensorFlow untuk mengklasifikasikan gambar berukuran 224x224 piksel ke dalam tiga kategori. Pada model CNN ditambahkan lapisan-lapisan kustom yang disesuaikan dengan kebutuhan. Adapun penyesuaian lapisan kustomisasi CNN dapat dilihat pada Tabel 3.

Tabel 3. Lapisan Kustomisasi CNN

Nama Lapisan	Nilai
Base Model	Dense121, InceptionResNetV2, InceptionV3, ResNet152v2
GlobalAveragePooling2D()	None
Flatten()	None
Dense	256, activation='relu'
Dropout	0.25
Dense	3, activation='softmax', name='classification'

Tabel 3 menunjukkan lapisan-lapisan yang digunakan pada penelitian ini, *Base Model* mencakup empat arsitektur yaitu DenseNet121, InceptionResNetV2, InceptionV3, dan ResNet152V2, yang digunakan untuk ekstraksi fitur. Setelah itu, terdapat lapisan *GlobalAveragePooling2D()* dan *Flatten()*, yang berfungsi untuk mereduksi dimensi fitur dan mengubahnya menjadi vektor satu dimensi. Selanjutnya, terdapat lapisan *dense* dengan 256 neuron dan fungsi aktivasi ReLU, yang bertugas memproses fitur secara non-linear. Lapisan *dropout* dengan nilai 0.25 digunakan untuk mencegah *overfitting* dengan menonaktifkan sebagian neuron selama proses pelatihan. Akhirnya, lapisan *dense*

terakhir memiliki 3 neuron dengan fungsi aktivasi *softmax*, yang menghasilkan probabilitas untuk 3 kelas *output* dan diberi nama *classification*.

Tabel 4. Pengaturan *Hyperparameter*

Nama Parameter	Pengaturan Parameter	Nilai
Adam	Learning Rate	0.0001
	Batch Size	16
SGDM	Learning Rate	0.0001
	Momentum	0.9
	Batch Size	16

Tabel 4 menjelaskan pengaturan *hyperparameter* untuk dua jenis optimisasi yang digunakan dalam pelatihan, yaitu Adam dan SGDM. Untuk optimisasi Adam, parameter yang diatur adalah *learning rate* sebesar 0.0001, yang menentukan seberapa besar pembaruan bobot dalam setiap langkah pelatihan, serta *batch size* sebesar 16, yang menunjukkan jumlah sampel data yang diproses sebelum pembaruan bobot dilakukan. Pada optimisasi SGDM, pengaturan parameter meliputi *learning rate* yang sama, yaitu 0.0001, nilai *momentum* sebesar 0.9, yang membantu mempercepat konvergensi dengan mempertahankan arah gradien sebelumnya, dan *batch size* sebesar 16. Kombinasi parameter ini dirancang untuk memastikan proses optimasi berjalan stabil dan efisien, dengan penyesuaian berbeda untuk masing-masing metode optimasi. Hasil performa dari pemodelan arsitektur CNN dapat dilihat pada tabel berikut.

Tabel 5. Performa Pemodelan Arsitektur DenseNet121

Hold-Out	Optimisasi	Akurasi Pelatihan	Akurasi Validasi	Akurasi Pengujian
70:30	Adam	99.10%	99.12%	99.04%
	SGDM	96.12%	96.17%	96.02%
80:20	Adam	98.91%	98.87%	99.04%
	SGDM	96.49%	96.81%	95.23%
90:10	Adam	98.46%	98.36%	99.36%
	SGDM	96.05%	96.27%	94.07%

Tabel 5 menunjukkan performa DenseNet121 dengan tiga skenario pembagian data yaitu 70:30, 80:20 dan 90:10 menggunakan optimisasi Adam dan SGDM. Optimisasi Adam memberikan akurasi lebih tinggi dibandingkan SGDM, terutama pada *hold-out* 90:10 dengan akurasi tertinggi 99.36%.

Tabel 6. Performa Pemodelan Arsitektur InceptionResNetV2

Hold-Out	Optimisasi	Akurasi Pelatihan	Akurasi Validasi	Akurasi Pengujian
70:30	Adam	99.10%	99.12%	99.04%
	SGDM	98.58%	98.93%	97.76%
80:20	Adam	99.97%	99.84%	99.36%
	SGDM	99.39%	100%	99.68%
90:10	Adam	92.56%	92.73%	91.08%
	SGDM	99.55%	99.57%	99.36%

Tabel 6 menunjukkan performa InceptionResNetV2 dengan pembagian data 70:30, 80:20 dan 90:10 menggunakan optimisasi Adam dan SGDM. Adam mencatat akurasi tertinggi pada 70:30 mencapai sebesar 99.04% dan pada SGDM mencapai akurasi tertinggi yaitu 99.68% pada *hold-out* 80:20.

Tabel 7. Performa Pemodelan Arsitektur InceptionV3

Hold-Out	Optimisasi	Akurasi Pelatihan	Akurasi Validasi	Akurasi Pengujian
70:30	Adam	99.10%	99.12%	99.04%
	SGDM	78.03%	76.80%	80.89%
80:20	Adam	97.88%	97.75%	98.40%
	SGDM	71.04%	71.07%	70.09%
90:10	Adam	98.46%	98.43%	98.72%
	SGDM	77.21%	76.98%	79.25%

Tabel 7 menunjukkan performa InceptionV3 dengan pembagian data 70:30, 80:20 dan 90:10 menggunakan optimisasi Adam dan SGDM. Optimisasi Adam memberikan akurasi lebih tinggi dibandingkan SGDM di semua skenario. Akurasi tertinggi diperoleh Adam pada *hold-out* 70:30 sebesar 99.04% sedangkan SGDM hanya mencapai

akurasi tertinggi sebesar 80.89% pada skenario yang sama. Performa SGDM secara keseluruhan menunjukkan hasil yang lebih rendah dibandingkan Adam, dengan akurasi terendah 70.09% pada *hold-out* 80:20.

Tabel 8. Performa Pemodelan Arsitektur ResNet152V2

Hold-Out	Optimisasi	Akurasi Pelatihan	Akurasi Validasi	Akurasi Pengujian
70:30	Adam	99.25%	99.25%	99.25%
	SGDM	98.52%	98.53%	98.50%
80:20	Adam	97.77%	97.61%	98.41%
	SGDM	98.39%	98.47%	98.08%
90:10	Adam	90.96%	91.09%	89.80%
	SGDM	99.35%	99.35%	99.36%

Tabel 8 menunjukkan performa model ResNet152V2 dengan pembagian data *hold-out* sama seperti sebelumnya yaitu 70:30, 80:20 dan 90:10 menggunakan optimisasi Adam dan SGDM. Pada skenario 70:30, Adam dan SGDM menghasilkan akurasi serupa, dengan Adam sedikit unggul. Sedangkan pada 80:20, SGDM memiliki akurasi pelatihan lebih tinggi pada data pelatihan dan validasi, tetapi pada data pengujian hampir seimbang dengan Adam lebih tinggi yaitu sebesar 98.41 dan SGDM 98.08%. Lalu pada 90:10, SGDM unggul di semua metrik dibandingkan Adam dengan perbedaan akurasi untuk SGDM sebesar 99.36% dan Adam sebesar 89.80%.

Semua tabel tersebut menunjukkan bahwa performa model dipengaruhi oleh arsitektur, pembagian data dan jenis optimisasi. SGDM secara umum memberikan hasil yang lebih stabil dan konsisten dibandingkan Adam, terutama pada pembagian data yang lebih kecil untuk validasi dan pengujian, seperti pada arsitektur DenseNet121 dan ResNet152V2. InceptionResNetV2 mencatat akurasi validasi dan pengujian maksimum dengan SGDM pada pembagian 80:20, sedangkan InceptionV3 menunjukkan performa yang kurang stabil di beberapa skenario.

3.5 Evaluasi Model

Selanjutnya melakukan evaluasi model untuk mengklasifikasikan data yang belum pernah dilihat model *deep learning* selama proses pelatihan maupun validasi menggunakan dataset pengujian dengan *confusion matrix*. Hasil evaluasi model arsitektur CNN dapat dilihat pada tabel berikut.

Tabel 9. Hasil Evaluasi Model Arsitektur DenseNet121

Hold-Out	Optimisasi	Presisi	Recall	F1-Score	Support	Akurasi
70:30	Adam	99.03%	99.03%	99.03%	315	99.04%
	SGDM	97.01%	92.42%	92.42%	403	96.03%
80:20	Adam	99.02%	98.96%	98.97%	313	99.04%
	SGDM	95.02%	95.18%	95.08%	315	95.23%
90:10	Adam	99.30%	99.41%	99.35%	157	99.36%
	SGDM	94.51%	90.45%	91.95%	135	94.07%

Tabel 9 menunjukkan hasil evaluasi model DenseNet121 menggunakan algoritma optimisasi Adam dan SGDM pada tiga skenario pembagian data yaitu 70:30, 80:20 dan 90:10. Hasilnya, Adam menghasilkan performa yang lebih tinggi dibandingkan SGDM pada semua metrik dan skenario. Pada skenario 70:30, Adam mencapai akurasi 99,04%, sedangkan SGDM hanya 96,03%. Hasil serupa terlihat pada pembagian 80:20 dan 90:10, di mana Adam tetap unggul dengan akurasi di atas 99%, sementara SGDM menunjukkan penurunan hingga 94,07%. Hal ini menunjukkan bahwa Adam lebih efektif dan stabil dalam mengoptimalkan performa model DenseNet121 dibandingkan SGDM.

Tabel 10. Hasil Evaluasi Model Arsitektur InceptionResNetV2

Hold-Out	Optimisasi	Presisi	Recall	F1-Score	Support	Akurasi
70:30	Adam	99.03%	99.03%	99.03%	315	99.04%
	SGDM	98.31%	95.70%	96.85%	403	97.76%
80:20	Adam	99.37%	99.26%	99.31%	315	99.38%
	SGDM	99.70%	99.70%	99.68%	313	99.68%
90:10	Adam	91.80%	91.81%	90.96%	157	91.08%
	SGDM	99.35%	99.44%	99.39%	157	99.36%

Tabel 10 menunjukkan hasil evaluasi model InceptionResNetV2 menggunakan algoritma optimisasi Adam dan SGDM, pada pembagian data 70:30, Adam mencapai akurasi sebesar 99,04%, sedangkan SGDM sedikit lebih rendah dibandingkan yaitu sebesar 97,76%. Pada pembagian 80:20, SGDM unggul dengan akurasi 99,68%, dibandingkan Adam yang mencatat akurasi 99,36%. Namun, pada pembagian data 90:10, SGDM menunjukkan performa lebih baik dengan akurasi sebesar 99,36%, sedangkan Adam hanya mencapai 91,08%. Meski Adam cenderung stabil di skenario awal, SGDM lebih unggul dalam mempertahankan performa, khususnya saat data latih lebih kecil, seperti pada

skenario 90:10. Hal ini menunjukkan bahwa SGDM lebih adaptif untuk arsitektur InceptionResNetV2 dalam kondisi data tertentu.

Tabel 11. Hasil Evaluasi Model Arsitektur InceptionV3

Hold-Out	Optimisasi	Presisi	Recall	F1-Score	Support	Akurasi
70:30	Adam	99.03%	99.03%	99.03%	315	99.04%
	SGDM	79.41%	78.81%	78.16%	403	80.89%
80:20	Adam	98.45%	98.28%	98.34%	313	99.40%
	SGDM	71.59%	69.78%	68.40%	313	70.92%
90:10	Adam	98.70%	98.66%	98.74%	157	98.72%
	SGDM	82.10%	71.09%	71.41%	135	79.25%

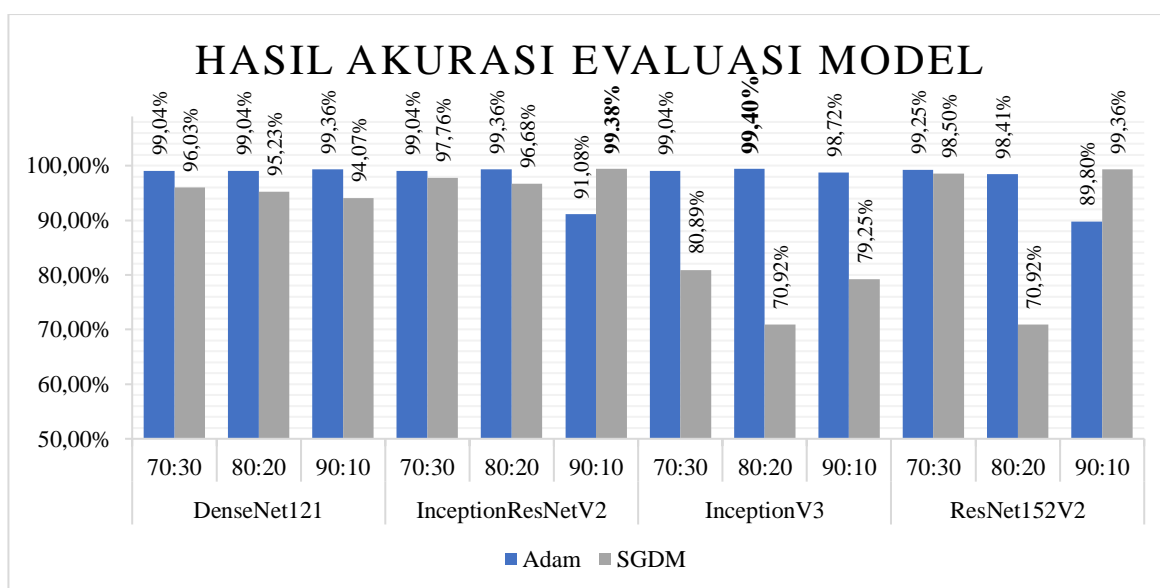
Tabel 11 hasil evaluasi model InceptionV3 akurasi model menunjukkan bahwa optimisasi Adam secara konsisten unggul di semua skenario pembagian data. Pada *hold-out* 70:30, Adam mencapai akurasi 99.04%, sementara SGDM hanya mencapai 80.89%. Untuk *hold-out* 80:20, Adam tetap unggul dengan akurasi 99.40%, sedangkan SGDM hanya 70.92%. Pada *hold-out* 90:10, Adam mencatatkan akurasi sebesar 98.72%, lebih tinggi dibandingkan SGDM yang mencapai 79.25%. Hal ini menegaskan bahwa Adam memberikan performa akurasi yang lebih baik dibandingkan SGDM pada arsitektur InceptionV3.

Tabel 12. Hasil Evaluasi Arsitektur ResNet152V2

Hold-Out	Optimisasi	Presisi	Recall	F1-Score	Support	Akurasi
70:30	Adam	99.41%	98.46%	98.91%	403	99.25%
	SGDM	98.46%	98.51%	98.48%	469	98.50%
80:20	Adam	99.41%	98.59%	98.47%	315	98.41%
	SGDM	71.59%	69.78%	68.40%	313	70.92%
90:10	Adam	90.87%	89.70%	89.70%	157	89.80%
	SGDM	99.32%	99.36%	99.32%	157	99.36%

Tabel 12 menunjukkan hasil akurasi model ResNet152V2 pada berbagai skenario *hold-out* dengan optimisasi Adam dan SGDM. Pada 70:30, Adam mencapai akurasi 99.25% sedikit lebih tinggi dibandingkan SGDM yang mencapai 98.50%. Pada 80:20, Adam unggul dengan akurasi 98.41%, sedangkan SGDM hanya mencapai 70.92%. Namun, pada 90:10, SGDM menunjukkan akurasi tertinggi sebesar 99.36%, mengungguli Adam yang hanya mencapai 89.80%. Secara keseluruhan, Adam lebih stabil di berbagai skenario, tetapi SGDM menunjukkan performa yang kompetitif pada *hold-out* tertentu.

3.6 Analisa dan Hasil



Gambar 8. Hasil Akurasi Evaluasi Model

Gambar 8 merupakan diagram perbandingan hasil akurasi evaluasi berbagai model *deep learning* yaitu DenseNet121, InceptionResNetV2, InceptionV3 dan ResNet152V2, dengan dua jenis optimisasi yang digunakan yaitu Adam dan SGDM. Grafik ini menunjukkan hasil akurasi pada tiga skenario pembagian data yaitu 70:30, 80:20 dan 90:10. Secara umum, optimisasi Adam menunjukkan performa yang konsisten dan lebih tinggi dibandingkan SGDM pada hampir semua kombinasi model dan skenario pembagian data. Pada DenseNet121, Adam mencapai akurasi

tertinggi sebesar 99.36% di scenario 90:10, sementara SGDM mencapai akurasi maksimum sebesar 96.03%. Model InceptionResNetV2 menunjukkan keunggulan SGDM dengan akurasi tertinggi 99.38% pada *hold-out* 90:10, dibandingkan Adam yang mencapai 99.36% pada *hold-out* 80:20.

Untuk model InceptionV3, Adam secara konsisten unggul, dengan akurasi tertinggi 99.40% pada *hold-out* 80:20, dibandingkan SGDM yang hanya mencapai 80.89%. Pada model ResNet152V2, SGDM menunjukkan hasil yang kompetitif, bahkan mengungguli Adam pada *hold-out* 90:10 dengan akurasi 99.36% dibandingkan 89.80%. Namun, pada skenario lainnya, Adam tetap menunjukkan keunggulan, seperti pada *hold-out* 70:30 dengan akurasi 99.25% dibandingkan SGDM yang mencapai 98.50%. Grafik ini secara keseluruhan menunjukkan bahwa penggunaan optimisasi Adam lebih andal dalam mencapai akurasi tinggi di berbagai model dan skenario pembagian data, meskipun pada kondisi tertentu SGDM dapat memberikan hasil yang kompetitif.

Hasil penelitian ini menunjukkan peningkatan performa dibandingkan studi sebelumnya, seperti penelitian Mujahid et al. (2022) yang juga menggunakan InceptionV3 untuk klasifikasi pneumonia dengan akurasi 99,29%, serta penelitian Kalkan et al. (2024) yang menggunakan ResNet152V2 dengan akurasi 98,29% untuk spesifikasi kanker paru-paru. Akurasi tertinggi pada penelitian ini, yaitu 99,40% dengan InceptionV3, dan 99,38% dengan InceptionResNetV2, menunjukkan bahwa pendekatan ini memberikan kontribusi signifikan dalam meningkatkan efisiensi dan akurasi klasifikasi.

Secara teknis, optimisasi Adam cenderung lebih unggul karena kemampuan adaptifnya dalam menyesuaikan laju pembelajaran selama pelatihan, yang memungkinkan model mencapai konvergensi lebih cepat dan stabil. Di sisi lain, SGDM lebih cocok untuk skenario dengan jumlah data pelatihan lebih kecil, seperti pada *hold-out* 90:10, karena dapat mempertahankan performa model melalui mekanisme momentum yang mengurangi osilasi selama pelatihan.

Selain itu, hasil ini memiliki implikasi praktis yang signifikan dalam sistem deteksi medis. Akurasi tinggi yang dicapai memungkinkan model ini digunakan sebagai alat bantu diagnostik untuk dokter radiologi, membantu penemuan dini kanker paru-paru pada tahap awal dengan lebih cepat dan akurat. Kecepatan prediksi yang tinggi juga dapat mempercepat proses diagnosis, memberikan peluang intervensi lebih cepat untuk pasien. Dengan demikian, model ini tidak hanya meningkatkan akurasi diagnosis, tetapi juga membantu mengurangi beban kerja dokter dan meminimalkan risiko kesalahan interpretasi dalam pengaturan klinis.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model *deep learning* untuk klasifikasi citra *CT Scan* kanker paru-paru dengan membandingkan beberapa arsitektur CNN yaitu DenseNet121, InceptionResNetV2, InceptionV3, dan ResNet152V2. Hasil menunjukkan bahwa arsitektur InceptionResNetV2 dengan optimisasi SGDM mencapai performa tertinggi pada *hold-out* 90:10 dengan akurasi sebesar 99,38%, sedangkan InceptionV3 dengan optimisasi Adam pada *hold-out* 80:20 menunjukkan hasil pengujian akurasi paling tinggi yaitu sebesar 99,40%. Proses *preprocessing* yang mencakup normalisasi dan augmentasi data serta penggunaan teknik *hold-out* yang beragam menjadi aspek inovatif dari penelitian ini, karena terbukti meningkatkan efektivitas pelatihan model dan akurasi hasil klasifikasi dibandingkan studi terdahulu. Selain dua arsitektur tersebut, DenseNet121 juga menunjukkan performa yang kompetitif dengan akurasi tertinggi sebesar 99,36% pada *hold-out* 90:10 menggunakan optimisasi Adam dan model ResNet152V2 juga mencapai akurasi hingga 99,36% pada skenario yang sama menggunakan SGDM. Dengan mempertimbangkan semua arsitektur, hasil penelitian ini memberikan gambaran komprehensif mengenai keunggulan berbagai pendekatan. Metode ini menunjukkan potensi besar dalam mendukung diagnosis dini kanker paru-paru melalui identifikasi fitur penting secara otomatis, yang dapat mengurangi kesalahan interpretasi manual. Penelitian ini memberikan dasar yang kuat untuk pengembangan lebih lanjut sistem berbasis *deep learning* dalam analisis citra medis. Direkomendasikan untuk penelitian selanjutnya menguji arsitektur tambahan dan dataset yang lebih besar guna meningkatkan generalisasi dan keandalan model untuk diterapkan dalam skala klinis.

REFERENCES

- [1] F. Bray Bsc 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, May 2024, doi: 10.3322/CAAC.21834.
- [2] A. Asuntha and A. Srinivasan, "Deep learning for lung Cancer detection and classification," *Multimed Tools Appl*, vol. 79, no. 11–12, pp. 7731–7762, Mar. 2020, doi: 10.1007/S11042-019-08394-3/METRICS.
- [3] S. Makaju, P. W. C. Prasad, A. Alsadoon, A. K. Singh, and A. Elchouemi, "Lung Cancer Detection using CT Scan Images," *Procedia Comput Sci*, vol. 125, pp. 107–114, Jan. 2018, doi: 10.1016/J.PROCS.2017.12.016.
- [4] V. Shah, R. Keniya, A. Shridharani, M. Punjabi, J. Shah, and N. Mehendale, "Diagnosis of COVID-19 using CT scan images and deep learning techniques," *Emerg Radiol*, vol. 28, no. 3, pp. 497–505, Jun. 2021, doi: 10.1007/S10140-020-01886-Y/TABLES/2.
- [5] W. Shen, M. Zhou, F. Yang, C. Yang, and J. Tian, "Multi-scale Convolutional Neural Networks for Lung Nodule Classification," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 9123, pp. 588–599, 2015, doi: 10.1007/978-3-319-19992-4_46.
- [6] J. Ker, L. Wang, J. Rao, and T. Lim, "Deep Learning Applications in Medical Image Analysis," *IEEE Access*, vol. 6, pp. 9375–9379, Dec. 2017, doi: 10.1109/ACCESS.2017.2788044.



- [7] P. Mishra, S. Lohumi, H. Ahmad Khan, and A. Nordon, “Close-range hyperspectral imaging of whole plants for digital phenotyping: Recent applications and illumination correction approaches,” *Comput Electron Agric*, vol. 178, p. 105780, Nov. 2020, doi: 10.1016/J.COMPAG.2020.105780.
- [8] J. Li, P. Jiang, Q. An, G. G. Wang, and H. F. Kong, “Medical image identification methods: A review,” *Comput Biol Med*, vol. 169, Feb. 2024, doi: 10.1016/J.COMPBIOMED.2023.107777.
- [9] Q. Zhang, L. T. Yang, Z. Chen, and P. Li, “A survey on deep learning for big data,” *Information Fusion*, vol. 42, pp. 146–157, Jul. 2018, doi: 10.1016/J.INFFUS.2017.10.006.
- [10] H. F. Nweke, Y. W. Teh, M. A. Al-garadi, and U. R. Alo, “Deep learning algorithms for human activity recognition using mobile and wearable sensor networks: State of the art and research challenges,” *Expert Syst Appl*, vol. 105, pp. 233–261, Sep. 2018, doi: 10.1016/J.ESWA.2018.03.056.
- [11] F. Bozkurt, “Classification of Blood Cells from Blood Cell Images Using Dense Convolutional Network,” *Journal of Science, Technology and Engineering Research*, vol. 2, no. 2, pp. 81–88, Dec. 2021, doi: 10.53525/JSTER.1014186.
- [12] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. A. Alemi, “Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning,” *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 31, no. 1, pp. 4278–4284, Feb. 2017, doi: 10.1609/AAAI.V31I1.11231.
- [13] N. Van Hieu and N. L. H. Hien, “Automatic Plant Image Identification of Vietnamese species using Deep Learning Models,” *International Journal of Engineering Trends and Technology*, vol. 68, no. 4, pp. 25–31, May 2020, doi: 10.14445/22315381/IJETT-V68I4P205S.
- [14] W. Gu, S. Bai, and L. Kong, “A review on 2D instance segmentation based on deep neural networks,” *Image Vis Comput*, vol. 120, p. 104401, Apr. 2022, doi: 10.1016/J.IMAVIS.2022.104401.
- [15] M. Mujahid, F. Rustam, R. Álvarez, J. Luis Vidal Mazón, I. de la T. Díez, and I. Ashraf, “Pneumonia Classification from X-ray Images with Inception-V3 and Convolutional Neural Network,” *Diagnostics 2022, Vol. 12, Page 1280*, vol. 12, no. 5, p. 1280, May 2022, doi: 10.3390/DIAGNOSTICS12051280.
- [16] M. Kalkan, M. S. Guzel, F. Ekinci, E. Akcapinar Sezer, and T. Asuroglu, “Comparative Analysis of Deep Learning Methods on CT Images for Lung Cancer Specification,” *Cancers 2024, Vol. 16, Page 3321*, vol. 16, no. 19, p. 3321, Sep. 2024, doi: 10.3390/CANCERS16193321.
- [17] T. Lakshmi Prasanthi and N. Neelima, “Improvement of Brain Tumor Categorization using Deep Learning: A Comprehensive Investigation and Comparative Analysis,” *Procedia Comput Sci*, vol. 233, pp. 703–712, Jan. 2024, doi: 10.1016/J.PROCS.2024.03.259.
- [18] J. Uddin, “Attention-Based DenseNet for Lung Cancer Classification Using CT Scan and Histopathological Images,” *Designs 2024, Vol. 8, Page 27*, vol. 8, no. 2, p. 27, Mar. 2024, doi: 10.3390/DESIGNS8020027.
- [19] M. A. Morid, A. Borjali, and G. Del Fiol, “A scoping review of transfer learning research on medical image analysis using ImageNet,” *Comput Biol Med*, vol. 128, p. 104115, Jan. 2021, doi: 10.1016/J.COMPBIOMED.2020.104115.
- [20] K. K. Kumar and S. Mandava, “Real-time bearing fault classification of induction motor using enhanced inception ResNet-V2,” *Applied Artificial Intelligence*, vol. 38, no. 1, Dec. 2024, doi: 10.1080/08839514.2024.2378270.
- [21] M. El-khatib, D. Popescu, O. Teodor, and L. Ichim, “Intelligent system based on multiple networks for accurate ovarian tumor semantic segmentation,” *Heliyon*, vol. 10, no. 17, Sep. 2024, doi: 10.1016/j.heliyon.2024.e37386.
- [22] A. H. M. Linkon, M. M. Labib, T. Hasan, M. Hossain, and M. E. Jannat, “Deep learning in prostate cancer diagnosis and Gleason grading in histopathology images: An extensive study,” *Inform Med Unlocked*, vol. 24, p. 100582, Jan. 2021, doi: 10.1016/J.IMU.2021.100582.
- [23] Y. Jing *et al.*, “A comprehensive survey of intestine histopathological image analysis using machine vision approaches,” *Comput Biol Med*, vol. 165, p. 107388, Oct. 2023, doi: 10.1016/J.COMPBIOMED.2023.107388.
- [24] O. Iparraguirre-Villanueva, V. Guevara-Ponce, O. R. Paredes, F. Sierra-Liñan, J. Zapata-Paulini, and M. Cabanillas-Carbonell, “Convolutional Neural Networks with Transfer Learning for Pneumonia Detection,” *International Journal of Advanced Computer Science and Applications*, vol. 13, no. 9, pp. 544–551, 2022, doi: 10.14569/IJACSA.2022.0130963.
- [25] T. Singh and D. K. Vishwakarma, “A deeply coupled ConvNet for human activity recognition using dynamic and RGB images,” *Neural Comput Appl*, vol. 33, no. 1, pp. 469–485, Jan. 2021, doi: 10.1007/S00521-020-05018-Y/METRICS.
- [26] S. Zorgui, S. Chaabene, B. Bouaziz, H. Batatia, and L. Chaari, “A Convolutional Neural Network for Lentigo Diagnosis,” *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 12157 LNCS, pp. 89–99, 2020, doi: 10.1007/978-3-030-51517-1_8/TABLES/4.
- [27] L. Abdelrahman, M. Al Ghamdi, F. Collado-Mesa, and M. Abdel-Mottaleb, “Convolutional neural networks for breast cancer detection in mammography: A survey,” *Comput Biol Med*, vol. 131, p. 104248, Apr. 2021, doi: 10.1016/J.COMPBIOMED.2021.104248.
- [28] D. M. Ibrahim, N. M. Elshennawy, and A. M. Sarhan, “Deep-chest: Multi-classification deep learning model for diagnosing COVID-19, pneumonia, and lung cancer chest diseases,” *Comput Biol Med*, vol. 132, p. 104348, May 2021, doi: 10.1016/J.COMPBIOMED.2021.104348.
- [29] F. J. M. Shamrat, S. Azam, A. Karim, K. Ahmed, F. M. Bui, and F. De Boer, “High-precision multiclass classification of lung disease through customized MobileNetV2 from chest X-ray images,” *Comput Biol Med*, vol. 155, p. 106646, Mar. 2023, doi: 10.1016/J.COMPBIOMED.2023.106646.
- [30] A. Tharwat, “Classification assessment methods,” *Applied Computing and Informatics*, vol. 17, no. 1, pp. 168–192, 2018, doi: 10.1016/J.ACI.2018.08.003/FULL/PDF.