

Analisa Gambar X-Ray Mammography dengan Convolution Neural Network pada Deep Learning dengan Arsitektur Resnet

Nur Islamiati Sanusi*, Siti Ramadhani, Muhammad Irsyad

Fakultas Sains dan Teknologi, Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim, Pekanbaru, Indonesia

Email: ¹*11850124994@students.uin-suska.ac.id, ²siti.ramadhani@uin-suska.ac.id, ³irsyadtech@uin-suska.ac.id

Email Penulis Korespondensi: 11850124994@students.uin-suska.ac.id

Submitted: 15/06/2023; Accepted: 30/06/2023; Published: 30/06/2023

Abstrak—Kanker adalah penyakit yang terjadi ketika sel-sel tubuh mengalami perubahan dan tumbuh secara tidak terkendali. Kanker payudara merupakan salah satu jenis kanker yang umum terjadi pada wanita di seluruh dunia. Deteksi dini kanker payudara sangat penting untuk meningkatkan tingkat kesembuhan. Mammography adalah metode pencitraan medis yang digunakan untuk deteksi dini kanker payudara. Dalam hal ini, teknologi deep learning dan pengklasifikasi terkomputerisasi, seperti Convolutional Neural Network (CNN) dengan model Resnet, telah digunakan dalam analisis dan prediksi gambar mammography dengan hasil yang menjanjikan. Studi-studi sebelumnya telah menunjukkan akurasi tinggi dalam klasifikasi massa payudara menjadi jinak atau ganas menggunakan CNN dan Resnet. Selain itu, CNN juga telah digunakan untuk klasifikasi kanker payudara ganas dan jinak, prediksi risiko kanker payudara, serta deteksi dan klasifikasi massa kanker payudara dengan tingkat akurasi yang memuaskan. Penggunaan deep learning dalam analisis citra medis, termasuk mammogram dan gambar X-ray, terbukti menjadi alat yang efektif dalam meningkatkan diagnosis dan pengobatan kanker. Data yang digunakan terdiri dari 322 gambar yang terbagi menjadi 7 kelas. Setelah dilakukan pengujian didapatkan akurasi sebesar 72% dengan perbandingan data uji dan data latih sebesar 90:10 dan nilai confusion matrix sehingga dapat disimpulkan bahwa metode resnet mengidentifikasi kanker payudara berdasarkan kelasnya.

Kata Kunci: Kanker Payudara; Deep Learning; Resnet; CNN; Mammography

Abstract—Cancer is a disease that occurs when cells in the body undergo changes and grow uncontrollably. Breast cancer is one of the common types of cancer that affects women worldwide. Early detection of breast cancer is crucial to improve the survival rate. Mammography is a medical imaging method used for the early detection of breast cancer. In this context, deep learning technology and computerized classifiers, such as Convolutional Neural Network (CNN) with the Resnet model, have been used for the analysis and prediction of mammography images with promising results. Previous studies have shown high accuracy in classifying breast masses as benign or malignant using CNN and Resnet. Furthermore, CNN has also been employed for the classification of malignant and benign breast cancer, prediction of breast cancer risk, as well as detection and classification of breast masses with satisfactory accuracy rates. The use of deep learning in medical image analysis, including mammograms and X-ray images, has proven to be an effective tool in improving cancer diagnosis and treatment. The dataset used consisted of 322 images divided into 7 classes. After testing, an accuracy of 72% was achieved with a 90:10 ratio of test data to training data, along with the corresponding confusion matrix values. Therefore, it can be concluded that the Resnet method is capable of identifying breast cancer.

Keywords: Breast Cancer; Deep Learning; Resnet; CNN; Mammography

1. PENDAHULUAN

Kanker adalah penyakit yang disebabkan oleh perubahan yang terjadi pada sel yang menyebar secara tidak terkendali. Sebagian besar sel kanker membentuk benjolan yang disebut tumor dan dinamai sesuai bagian tubuh tempat asalnya [1]. Kanker adalah penyakit yang terjadi ketika sel abnormal tumbuh secara tidak terkendali dengan cara mengabaikan aturan normal pembelahan sel yang menyebabkan pertumbuhan dan proliferasi sel abnormal tidak terkendali apabila dibiarkan mengarah pada pembentukan metastasis dan menyerang jaringan disekitar dan bagian tubuh lainnya [2].

Kanker payudara adalah salah satu penyakit ganas yang menyerang jaringan payudara yang umum untuk di diagnosis pada wanita diseluruh dunia. Salah satunya di Indonesia, 80% kanker payudara mengacu pada penyakit tunggal hingga 21 sub kategori histologis, insiden dan tingkat kematian[3]. Walaupun kanker payudara dapat timbul pada kedua jenis kelamin, prevalensinya lebih tinggi pada wanita. Berdasarkan data dari World Health Organization Globocan 2020, kanker payudara menyumbang sekitar 11,4% dari total kasus kanker di dunia. Di Indonesia, kanker payudara merupakan jenis kanker yang paling sering terjadi, dengan frekuensi relatif sebesar 18,6% berdasarkan Pathological Based Registration. Lebih dari 80% kasus kanker payudara di Indonesia terdeteksi pada tahap lanjut, sehingga pengetahuan mengenai pencegahan, diagnosis dini, dan pengobatan sangatlah penting [4].

Salah satu metode pencitraan medis yang digunakan untuk deteksi dini kanker payudara adalah mammography, yaitu prosedur sinar-X dosis rendah yang memvisualisasikan struktur internal payudara [5]. Mammography digunakan untuk mendeteksi kelainan pada tahap awal, seperti klasifikasi mikro dan massa, yang merupakan tanda awal kanker payudara yang hanya dapat dideteksi melalui modalitas pencitraan [6]. Deteksi dini kanker payudara melalui mammography telah terbukti dapat menurunkan angka kematian [7]. Program mammography dianggap memungkinkan untuk mendeteksi tanda awal kanker dimana struktur nodular dan dalam dimensi 0,1 hingga 1 mm.

Dalam hal ini, teknologi deep learning dan pengklasifikasi terkomputerisasi dapat membantu dalam analisis dan prediksi gambar mammography [8]. Deep learning dapat meniru pengoperasian otak manusia menggunakan banyak lapisan jaringan saraf konvensional yang dapat mempelajari pola tertentu langsung dari data dan menghasilkan prediksi otomatis dari masukan. Secara teknis, metode Deep learning dapat dibangun dengan menyusun sederhana namun nonlinier lapisan yang mengubah representasi input mentah menjadi tingkat yang lebih tinggi dan sedikit lebih abstrak [9]. Dalam pencitraan medis, deep learning digunakan untuk mendeteksi sel kanker secara otomatis. Penggunaan deep learning dalam analisis citra medis telah menunjukkan hasil yang menjanjikan, terutama dengan adanya daya komputasi yang tinggi dari Graphics Processing Unit (GPU) [10].

Studi yang dilakukan oleh Tsochatzidis et al. pada tahun 2019 [3] menerapkan mammography dalam menganalisis gambar X-ray kanker payudara menggunakan empat algoritma dalam convolutional neural network (CNN), yaitu AlexNet, VGG, GoogleNet/Inception, dan Resnet. Dalam penelitian tersebut, Resnet terbukti memiliki kinerja yang lebih baik dalam klasifikasi massa payudara menjadi jinak atau ganas.

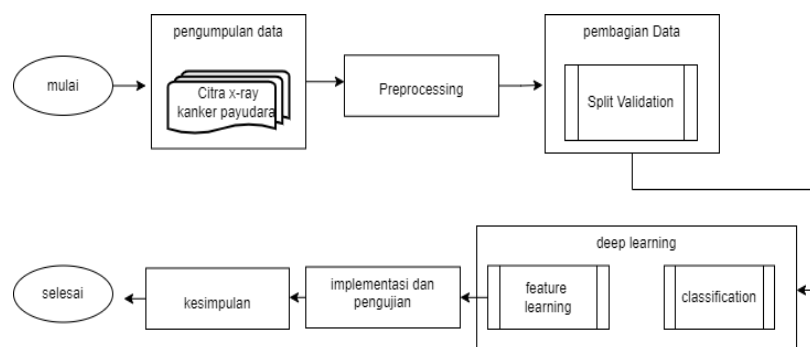
Convolution Neural Network menjadi metode dalam bidang pengenalan citra, yang memiliki ketahanan yang kuat terhadap pengenalan distorsi, penskalaan, dan perpindahan. Akan tetapi dengan bertambahnya jumlah lapisan jaringan, seiring bertambahnya waktu CNN memiliki jenis yang baru yaitu Resnet untuk mengurangi masalah seperti kesulitan dalam pelatihan, hilangnya gradien [11] ResNet (Residual Network) terdiri dari lapisan konvolusi yang dirumuskan ulang yang mempelajari fungsi residual dengan mengacu pada input sebagai hasil awal langsung ke input memastikan integritas informasi. ResNet memiliki jaringan yang lebih dalam dibanding dengan VGG dengan jaringan terdalam yaitu berjumlah 152 layout [12]. Resnet memperkenalkan modul residual kedalam jaringan saraf dan meninggalkan struktur jaringan yang berlebihan untuk mempercepat kecepatan operasi. Prinsip utamanya adalah jika lapisan tambahan dibangun sebagai pemetaan identitas, model yang lebih dalam seharusnya tidak memiliki lebih banyak kesalahan pelatihan daripada ekuivalen dangkal yang sesuai [13].

Berdasarkan beberapa penelitian terkait dapat dilihat bahwa analisis gambar X-ray mammography menggunakan Convolutional Neural Network (CNN) dalam deep learning dengan menggunakan model Resnet telah menghasilkan akurasi yang tinggi. Resnet 18 dan Resnet 50 adalah varian Resnet yang paling banyak digunakan. Salah satu studi menunjukkan bahwa penggunaan ResNet 101 dalam arsitektur imageNet juga menghasilkan akurasi yang tinggi [14]. Beberapa penelitian juga telah dilakukan untuk klasifikasi kanker payudara ganas dan jinak menggunakan convolutional neural network dalam analisis gambar X-ray mammography. Hasil penelitian menunjukkan akurasi yang tinggi, misalnya 97,46% [15] dan 98,59% untuk prediksi kanker payudara [16], serta akurasi deteksi daerah massa hingga 91,86% [6]. Selain itu, terdapat juga penelitian yang menggunakan convolutional neural network dalam analisis citra mammogram untuk memprediksi risiko kanker payudara berdasarkan faktor-faktor seperti usia, area padat, dan persentase kepadatan [17]. Hasilnya menunjukkan bahwa model yang disesuaikan dengan usia memiliki kinerja yang lebih baik dalam memprediksi risiko kanker payudara dibandingkan dengan faktor lainnya [3]. Selain itu, terdapat juga penelitian yang menggunakan convolutional neural network untuk deteksi dan klasifikasi massa kanker payudara, dengan akurasi mencapai 83,33% - 88,2% untuk citra benign dan 76,92% - 83,3% untuk citra ganas [18]. Penelitian lainnya juga mengusulkan penggunaan metode deep learning untuk klasifikasi mammogram jinak dan ganas, dengan tujuan mencapai akurasi yang lebih tinggi [8]. Terakhir, terdapat juga penelitian yang menggunakan Resnet dalam analisis citra untuk mendeteksi kanker kolorektal, dengan akurasi antara 73% - 88% dan sensitivitas antara 64% - 96% [19].

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Metodologi penelitian adalah serangkaian langkah atau prosedur yang digunakan dalam melakukan penelitian. Metodologi ini memberikan panduan dan mengatur setiap tahapan dari awal hingga akhir penelitian. Tujuan dari metodologi penelitian adalah untuk memastikan bahwa semua tahapan yang dilakukan berjalan secara terstruktur. Gambar 1 menunjukkan tahapan-tahapan dalam penelitian sebagai berikut:



Gambar 1. Bagan Penelitian Analisa X-ray mammography dengan convolution neural network pada deep learning dengan arsitektur resnet.

2.2 Pengumpulan Data

Pengumpulan data yang diambil dalam Mammography Analysis Society (MIAS) yang berasal dari Kaggle. Dengan kumpulan dataset dengan jumlah 322 total citra kanker payudara. Dimana terdapat citra yang dibagi menjadi 7 kelas yang terdiri dari Architectural distortion (ARCH), Asymmetry (ASYM), Other ill-defined masses (MISC), Normal (NORM), Calcification (CALC), Well-defined/ circumscribed masses (CIRC), Spiculated masses (SPIC). Dengan ukuran gambar 1024 x 1024 pixel.

2.3 PreProcessing

Tujuan dari proses preprocessing adalah untuk mempermudah ekstraksi fitur. Dalam penelitian ini, proses preprocessing yang dilakukan adalah resize. Resize adalah metode yang digunakan untuk mengubah ukuran citra dengan cara mengurangi ukuran citra tersebut secara vertikal atau horizontal. Pada penelitian ini, citra diresize dari 256x256 piksel menjadi 128x128 piksel dan 64x64 piksel. Hal ini bertujuan untuk mempercepat dan mempermudah proses perhitungan.

2.4 Pembagian data

Split Validation merupakan metode yang digunakan untuk membagi data menjadi dua yaitu data testing 20% dan data training 80% secara random [20].

2.5 Deep learning

Penelitian ini menggunakan metode Deep Learning dengan menggunakan arsitektur Resnet 101. Deep learning terdiri dari dua tahapan utama, yaitu pembelajaran fitur (feature learning) dan klasifikasi (classification). Rancangan arsitektur Deep Learning pada penelitian ini dijelaskan secara visual dalam Gambar 2 sebagai berikut:



Gambar 2. Proses Deep Learning dengan menggunakan arsitektur resnet 101.

Berikut tahapan dari tahapan arsitektur Resnet 101 diatas dalam menghasilkan klasifikasi gambar :

1. Citra input berukuran 256 x 256 pixel.
2. Citra input akan ditambahkan zero padding berukuran 3 x 3 dan output citra berukuran 256 x 256.
3. Citra berukuran 256 x 256 dilakukan operasi convolutional dengan filter 7 x 7 dengan 64 channel dan stride berukuran 2 dan output citra berukuran 128 x 128.
4. Citra berukuran 128 x 128 dilakukan operasi fungsi batch normalization.
5. Citra berukuran 128 x 128 akan dilakukan operasi activation function menggunakan ReLu.
6. Citra berukuran 128 x 128 ditambahkan zero padding berukuran 1 x 1 dan output citra berukuran 128 x 128.
7. Citra berukuran 128 x 128 akan dilakukan operasi max pooling berukuran 3 x 3 dan stride 2.
8. Citra berukuran 128 x 128 dilakukan operasi convolusi block dengan filter 1 x 1 channel 64, 3 x 3 channel 64, 1 x 1 channel 256 dan serta stride = 1.
9. Setelah dilakukan convolusi block diatas maka akan dilakukan operasi identity block dengan filter 1 x 1 channel 64, 3 x 3 channel 64, 1 x 1 channel 256 dan stride = 1 yang dilakukan perulangan sebanyak 2 kali. Output dari proses tahapan ini menghasilkan ukuran citra 63 x 63 pixel.
10. Citra berukuran akan menjalani operasi convolusi block dengan menggunakan filter berukuran 1 x 1 channel, 3 x 3 channel dengan 128 saluran, dan 1 x 1 channel dengan 5 saluran, dengan stride sebesar 1.
11. Setelah dilakukan convolusi block diatas maka akan dilakukan operasi identity block dengan filter 1 x 1 channel 128, 3 x 3 channel 128, 1 x 1 channel 512 dan stride = 1 yang dilakukan perulangan sebanyak 3 kali. Output dari proses tahapan ini menghasilkan ukuran citra 32 x 32 pixel.
12. Citra berukuran 32 x 32 dilakukan operasi convolusi block dengan filter 1 x 1 channel 256, 3 x 3 channel 256, 1 x 1 channel 1024 dan serta stride = 1.
13. Setelah dilakukan convolusi block diatas maka akan dilakukan operasi identity block dengan filter 1 x 1 channel 256, 3 x 3 channel 256, 1 x 1 channel 1024 dan stride = 1 yang dilakukan perulangan sebanyak 22 kali. Output dari proses tahapan ini menghasilkan ukuran citra 16 x 16 pixel.

14. Citra berukuran 16 x 16 dilakukan operasi convolusi block dengan filter 1 x 1 channel 512, 3 x 3 channel 512, 1 x 1 channel 2048 dan serta stride = 1.
15. Setelah dilakukan convolusi block diatas maka akan dilakukan operasi identity block dengan filter 1 x 1 channel 512, 3 x 3 channel 512, 1 x 1 channel 2048 dan stride = 1 yang dilakukan perulangan sebanyak 2 kali. Output dari proses tahapan ini menghasilkan ukuran citra 7 x 7 pixel .
16. Output dari tahap konvolusi sebelumnya akan diolah dengan menambahkan operasi average pooling.
17. Dilakukan proses flatten, sehingga akan menghasilkan output array satu dimensi atau 1x1.
18. Output dari operasi flatten akan diteruskan ke dalam lapisan fully connected layer pada jaringan saraf dengan jumlah neuron sebanyak 2048.
19. Setelah proses pada jaringan saraf selesai, akan dihasilkan nilai bobot yang kemudian digunakan dalam proses klasifikasi menggunakan metode softmax.
20. Hasil dari proses klasifikasi akan menghasilkan kelas data sebagai output.

2.6 Implementasi dan Pengujian

Pada tahap ini, model Resnet 101 diimplementasikan berdasarkan analisis dan perancangan yang telah dilakukan. Implementasi dilakukan dengan menjalankan model Resnet 101 tersebut. Tahap pengujian dilakukan untuk memastikan bahwa model tersebut berfungsi dengan baik dan untuk mengevaluasi tingkat akurasi yang diperoleh. Metode pengujian untuk model Resnet 101 ini didasarkan pada perancangan skenario eksperimen. Eksperimen yang dilakukan adalah menguji dan membandingkan tingkat akurasi antara penggunaan data asli dengan data augmented, dengan skenario pembagian dataset sebesar 75%:25%, 70%:30%, 80%:20%, dan 90%:10%.

2.7 Evaluasi Matrix

Evaluasi matrix dilakukan dengan mempertimbangkan beberapa faktor, termasuk akurasi dan matrix kebingungan. Matrix kebingungan merupakan alat pengukuran yang digunakan dalam machine learning. Matrix kebingungan merepresentasikan hasil kelas prediksi, sementara kolom merepresentasikan hasil kelas sebenarnya, sehingga dapat menghitung semua kemungkinan kasus dalam masalah klasifikasi [21]. Dalam confusion matrix, terdapat beberapa matrix yang penting, yaitu presisi, recall, dan F1 score. Akurasi mengukur sejauh mana prediksi yang benar dibandingkan dengan keseluruhan data. Presisi mengukur sejauh mana prediksi positif yang benar dibandingkan dengan total prediksi positif. Recall mengukur sejauh mana nilai positif yang terprediksi dengan benar dibandingkan dengan semua data yang sebenarnya positif. F1 score merupakan rata-rata harmonik antara presisi dan recall. Akurasi dan confusion matrix dapat dihitung menggunakan persamaan (1), (2), (3), dan (4).

$$Akurasi = \frac{True\ Positive + True\ Negative}{True\ Positive + True\ Negative + True\ Positive + True\ Negative} \quad (1)$$

$$Presisi = \frac{True\ Positive}{True\ Positive + False\ Positive} \quad (2)$$

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative} \quad (3)$$

$$F1\ score = \frac{2 \times Recall \times Presisi}{Recall + Presisi} \quad (4)$$

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Data pada penelitian menggunakan dataset MIAS mammography yang diambil pada kanggle (kanggle.com) data yang diperoleh sebanyak 322 image dengan 7 kelas yang dijadikan model untuk menentukan benign (jinak) dan malignant (ganas) seperti yang ditertera pada tabel 1.

Tabel 1. Jumlah data perkelas pada dataset MIAS Mammography

Nama	Jumlah
Architectural Distortion (ARCH)	19
Asymmetry (ASYM)	15
Calcification (CALC)	25
Well-defined/circumscribed masses (CIRC)	23
Other, ill-defined masses (MISC)	14
Normal (NORM)	207
Spiculated Masses (SPIC)	19

3.2 Preprocessing citra

Pada tahap ini, ukuran pixel yang berbeda pada setiap citra akan diubah menjadi sama. Proses ini berlaku secara serupa baik pada data pelatihan maupun data pengujian. Data Citra atau gambar X-ray mammography awal

memiliki resolusi 1024 x 1024 pixel. Dalam penelitian ini, dimensi citra harus diubah agar memiliki ukuran seragam sebesar 256 x 256 pixel. Dalam tahap preprocessing, citra-citra dengan ukuran pixel yang berbeda akan diubah agar memiliki ukuran pixel yang sama disebut dengan resize. Dalam tahapan preprocessing ada beberapa tahapan yang diperlukan dalam preprocessing seperti berikut:

3.2.1 Pemindahan Kelas Data Citra

Data yang diperoleh perlu untuk menempatkannya sesuai kelas pada citra. Maka Dalam dataset terdapat 7 kelas dan diperlukan pemisahan data citra sesuai kelas.

3.2.2 Pengubahan Format Data

Data awal yang memiliki format PGM atau format data untuk menyimpan gambar grayscale. Untuk memudahkan proses preprocessing maka data diubah PNG (Portable Network Graphic).

3.2.3 Augmentasi Citra

Augmentasi citra adalah solusi untuk mengatasi keterbatasan data dalam pelatihan jaringan saraf. Dengan mengambil sampel kebisingan dari data pelatihan yang tidak ada dalam data pengujian, augmentasi citra melibatkan penerapan deformasi pada sampel-sampel pelatihan yang telah diberi anotasi. Hal ini menghasilkan data pelatihan baru yang tidak redundan. Augmentasi citra merupakan cara Regularisasi yang digunakan untuk mengurangi overfitting model dengan meningkatkan jumlah data pelatihan hanya dengan menggunakan informasi asli saat ini [22].

3.3 Pembuatan Model Convolution Neural Network

Layer tersebut diganti sesuai dengan output kategori yang relevan dengan penelitian. Pada penelitian ini, digunakan arsitektur Resnet 101 sebagai desain arsitektur. Resnet 101 memiliki kekhasan dalam kedalaman jaringannya, yaitu memiliki total 347 lapisan yang dimulai dari input_1 hingga new_classoutput. Setelah menyusun arsitektur model, langkah selanjutnya adalah mempersiapkan proses pelatihan model. Proses pelatihan pada pembuatan model Convolution Neural network ini disesuaikan dengan parameter pelatihan yang tercantum dalam Tabel 2.


Tabel 2. Parameter proses pelatihan pada pembuatan model Convolution Neural network

No	Parameter	Nilai
1	Optimizer	Adam
2	Loss function	Crossentropy
3	Train split	80%
4	Validation split	20%
5	Epoch	10
6	Batch size	32
7	Learning Rate	0,0001

3.4 Hasil Pengujian

Hasil dari proses training dan testing dievaluasi menggunakan confusion matrix. Model tersebut akan menghasilkan nilai akurasi, presisi, recall, dan f1 score. Dimana data latih dan data uji berdasarkan beberapa scenario dengan menggunakan model Resnet 101. Berikut hasil beberapa experiment yang dilakukan.

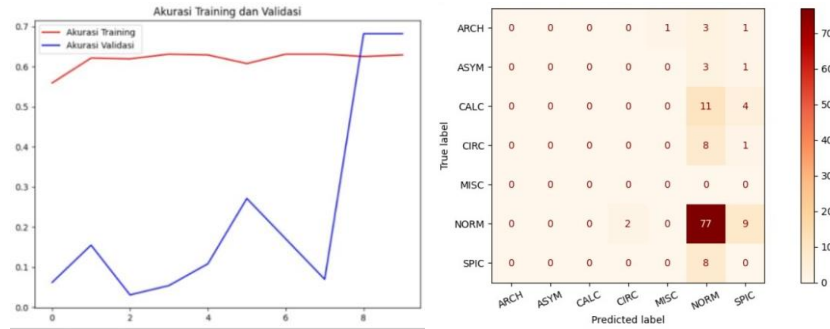
Skenario 1 Dalam skenario ini, data latih dan data uji dibagi dengan rasio 90%:10%, yang berarti terdapat 548 data latih dan 61 data uji. Proses pelatihan model memakan waktu 1 jam 6 menit. Setelah melalui pelatihan, akurasi uji terbaik yang diperoleh adalah 72%. Evaluasi model menggunakan confusion matrix menghasilkan presisi sebesar 0.11, recall sebesar 0.16, dan skor F1 sebesar 0.13. Akurasi dan confusion matrix ini ditampilkan secara visual dalam Gambar 3.



Gambar 3 Visualisasi Akurasi dan Confusion matrix pada scenario 1


Skenario 2 Pada skenario ini, data latih dan data uji memiliki rasio 80%:20%, dengan 515 data latih dan 129 data uji. Waktu pelatihan model sama dengan skenario sebelumnya. Hasil akurasi uji terbesar pada skenario

ini adalah 68%. Dalam evaluasi model menggunakan confusion matrix, diperoleh presisi sebesar 0.09, recall sebesar 0.14, dan skor F1 sebesar 0.11. Visualisasi akurasi dan confusion matrix ini ditampilkan dalam Gambar 4.



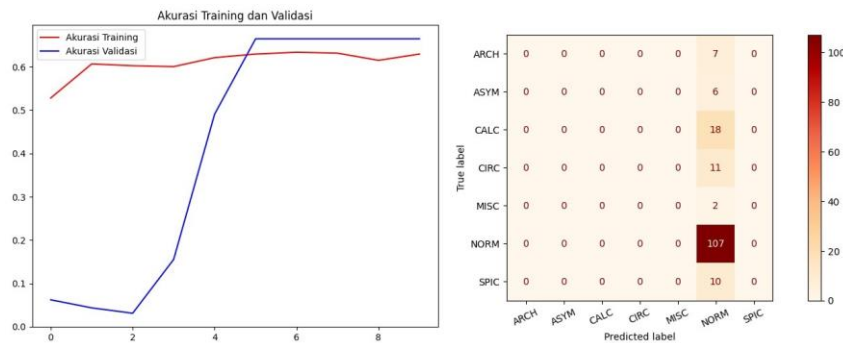
Gambar 4. Visualisasi Akurasi dan Confusion matrix pada skenario 2

Skenario 3 dilakukan data latih dan data uji sebesar 70%:30% dengan jumlah 451 data latih dan 193 data uji. Pelatihan model membutuhkan waktu 1 jam 6 menit. Setelah melakukan pelatihan model maka didapatkan hasil akurasi uji terbesar sebesar 63%. Selanjutnya tahap evaluasi model menggunakan confusion matrix didapatkan presisi sebesar 0.09, Recall 0.13, dan f1 score sebesar 0.11. Visualisasi akurasi dan confusion matrix yang ditunjukkan pada Gambar 5.



Gambar 5. Visualisasi Akurasi dan Confusion matrix skenario 3

Skenario 4 melibatkan pembagian data latih dan data uji dengan proporsi 75%:25%, yang berarti terdapat 480 data latih dan 161 data uji. Proses pelatihan model memakan waktu 1 jam 6 menit. Setelah melalui pelatihan model, hasil akurasi uji terbaik yang diperoleh adalah sebesar 70%. Selanjutnya, tahap evaluasi model dilakukan menggunakan confusion matrix yang menghasilkan presisi sebesar 0.1, recall sebesar 0.15, dan f1 score sebesar 0.12. Akurasi dan confusion matrix ini ditampilkan secara visual dalam Gambar 5.



Gambar 6. Visualisasi Akurasi dan Confusion matrix skenario 4

3.5 Hasil Pengujian keseluruhan

Dalam eksperimen yang dilakukan, model Resnet 101 diuji dengan berbagai skenario yang berbeda. Evaluasi dilakukan menggunakan confusion matrix untuk mendapatkan akurasi, presisi, recall, dan f1 score. Hasil eksperimen tersebut memberikan informasi penting tentang performa model. Berikut tampilan hasil dari evaluasi dan akurasi pada tabel 3.

Tabel 3. Hasil visualisasi akurasi dan confusion matrix dari semua skenario

skenario	akurasi	Presisi	Recall	F1 score
1	72%	0.11	0.16	0.13

skenario	akurasi	Presisi	Recall	F1 score
2	68%	0.09	0.14	0.11
3	63%	0.09	0.13	0.11
4	70%	0.11	0.15	0.12

Pada skenario pertama, data latih dan data uji memiliki rasio 90:10, dengan 548 data latih dan 61 data uji. Waktu pelatihan model adalah 1 jam 6 menit. Setelah pelatihan, model mencapai akurasi uji terbesar sebesar 72%. Namun, presisi, recall, dan f1 score yang dihasilkan masih relatif rendah, yaitu 0.11, 0.16, dan 0.13 secara berturut-turut. Skenario kedua melibatkan data latih dan data uji dengan rasio 80:20, dengan jumlah 515 data latih dan 129 data uji. Waktu pelatihan model tetap sama dengan skenario sebelumnya. Hasilnya menunjukkan akurasi uji terbesar sebesar 68%, sedangkan presisi, recall, dan f1 score adalah 0.09, 0.14, dan 0.11.

Pada skenario ketiga, data latih dan data uji memiliki rasio 70:30, dengan jumlah 451 data latih dan 193 data uji. Waktu pelatihan model tetap sama dengan eksperimen sebelumnya. Hasil evaluasi menunjukkan akurasi uji terbesar sebesar 63%. Presisi, recall, dan f1 score yang didapatkan adalah 0.09, 0.13, dan 0.11. Skenario keempat melibatkan data latih dan data uji dengan rasio 75%:25%, dengan jumlah 480 data latih dan 161 data uji. Waktu pelatihan model juga tetap sama. Pada skenario ini, model mencapai akurasi uji terbesar sebesar 70%. Presisi, recall, dan f1 score yang dihasilkan adalah 0.11, 0.15, dan 0.12.

Untuk melakukan pengujian beberapa eksperimen dilakukan pengujian scenario selanjutnya untuk menentukan benign dan malignant dalam model yang telah ditentukan atau dalam 7 kelas dataset MIAS mammography. Dengan skenario keempat 75%:25% dilakukan eksperimen dengan jumlah 480 data latih dan 161 data uji. Waktu pelatihan model juga tetap sama. Pada skenario ini, kelas yang dijadikan model akan mencari akurasi pada kanker benign atau jinak dan malignant atau ganas mencapai akurasi uji terbesar sebesar 35%. Presisi, recall, dan f1 score yang dihasilkan adalah 0.17, 0.5, dan 0.27.

Hasil evaluasi model menunjukkan akurasi uji sebesar 35%. Akurasi merupakan metrik yang mengukur sejauh mana model dapat memprediksi dengan benar seluruh kelas (benign dan malignant). Dalam skenario ini, akurasi yang diperoleh tampaknya tidak memenuhi tujuan untuk mencapai akurasi uji sebesar 35%. Selanjutnya, kita dapat melihat nilai presisi, recall, dan f1 score yang dihasilkan. Presisi adalah metrik yang mengukur sejauh mana prediksi positif (dalam hal ini benign atau malignant) yang dilakukan oleh model adalah benar. Dalam skenario ini, presisi sebesar 0.17 menunjukkan bahwa model memiliki tingkat kesalahan yang tinggi dalam memprediksi kelas dengan benar. Recall adalah metrik yang mengukur sejauh mana model dapat menemukan kembali (recall) sebagian besar sampel yang benar positif (benign atau malignant). Dalam skenario ini, recall sebesar 0.5 menunjukkan bahwa model memiliki tingkat pemulihan yang lebih baik daripada presisi, tetapi masih belum optimal. F1 score adalah metrik yang menggabungkan presisi dan recall menjadi satu skor yang mencerminkan keseimbangan antara keduanya. Dalam skenario ini, f1 score sebesar 0.27 menunjukkan bahwa model memiliki keseimbangan yang rendah antara presisi dan recall. Berdasarkan hasil analisis ini, dapat disimpulkan bahwa model yang digunakan dalam skenario ini tidak mencapai tingkat akurasi, presisi, recall, dan f1 score yang diinginkan. Mungkin perlu dilakukan peninjauan ulang terhadap model dan pendekatan yang digunakan untuk meningkatkan performa klasifikasi kanker dalam kasus ini.

4.KESIMPULAN

Penelitian ini melakukan Analisa gambar x-ray mammography pada kanker payudara menggunakan Resnet 101. Terdapat 7 kelas dalam kanker payudara yaitu ada Architectural distortion (ARCH), Asymmetry (ASYM), Other ill-defined masses (MISC), Normal (NORM), Calcification (CALC), Well-defined/ circumscribed masses (CIRC), Spiculated masses (SPIC). Mode uji yang telah dilakukan dengan beberapa eksprimen dari scenario 1 sampai 4 mendapatkan kesimpulan dimana scenario terbaik yaitu skenario 1 dengan mendapatkan akurasi 72% akan tetapi hasil keempat skenario tersebut, dapat dilihat variasi performa model Resnet 101 Meskipun akurasi uji terbesar mencapai 72%, presisi, recall, dan f1 score cenderung rendah dengan nilai sekitar 0.1-0.15. Visualisasi akurasi dan confusion matrix juga memberikan informasi tentang distribusi kelas pada data uji. Perlu dicatat bahwa hasil ini sangat bergantung pada karakteristik dataset yang digunakan dan pengaturan eksperimen yang dilakukan. Performa model dapat dipengaruhi oleh faktor-faktor seperti jumlah data latih, rasio data latih dan uji, serta kualitas dan representativitas dataset. Untuk meningkatkan performa model, beberapa langkah yang dapat diambil antara lain adalah memperluas jumlah data latih untuk meningkatkan variasi, mengoptimalkan hyperparameter learning rate dan jumlah epoch, melakukan augmentasi data untuk melatih model dengan variasi yang lebih banyak, serta mencoba menggunakan arsitektur model yang lebih canggih selain Resnet 101. Untuk penelitian lebih lanjut, disarankan menggunakan jumlah data yang lebih besar agar dapat meningkatkan akurasi dan matriks kebingungan.

REFERENCES

- [1] K. Charan, Saira.Khan,Muhammad Jaleed.Khurshid, "Breast Cancer Detection in Mammograms using Convolutional Neural Network," Breast Cancer Detect. Mammograms using Convolution Nural Netw., no. 978-1-5386-1370-2/18, pp. 1-5, 2018, doi: 10.1007/978-981-16-1244-2_7.
- [2] S. Z. Ramadan, "Methods Used in Computer-Aided Diagnosis for Breast Cancer Detection Using Mammograms: A

- Review,” *J. Healthc. Eng.*, vol. 2020, 2020, doi: 10.1155/2020/9162464.
- [3] L. Tsochatzidis, L. Costaridou, and I. Pratikakis, “Deep learning for breast cancer diagnosis from mammograms — A comparative study,” *J. Imaging*, vol. 5, no. 3, Mar. 2019, doi: 10.3390/jimaging5030037.
- [4] P. Stiefelhagen, “Wie Sie die „Pantozolitis“ loswerden,” *MMW-Fortschritte der Medizin*, vol. 160, no. 10, p. 12, 2018. doi: 10.1007/s15006-018-0554-5.
- [5] S. S. M. Khairi et al., “Deep Learning on Histopathology Images for Breast Cancer Classification: A Bibliometric Analysis,” *Healthc.*, vol. 10, no. 1, Jan. 2022, doi: 10.3390/healthcare10010010.
- [6] O. F. Ereken and C. Tarhan, “Breast Cancer Detection using Convolutional Neural Networks,” in *ISMSIT 2022 - 6th International Symposium on Multidisciplinary Studies and Innovative Technologies, Proceedings*, Mar. 2022, pp. 597–601. doi: 10.1109/ISMSIT56059.2022.9932694.
- [7] A. N. R. Hakim, P. Prajitno, and D. S. Soejoko, “Microcalcification detection in mammography image using computer-aided detection based on convolutional neural network,” in *AIP Conference Proceedings, American Institute of Physics Inc.*, Mar. 2021. doi: 10.1063/5.0047828.
- [8] H. Li, S. Zhuang, D. ao Li, J. Zhao, and Y. Ma, “Benign and malignant classification of mammogram images based on deep learning,” *Biomed. Signal Process. Control*, vol. 51, pp. 347–354, May 2019, doi: 10.1016/j.bspc.2019.02.017.
- [9] S. S. Aboutalib, A. A. Mohamed, W. A. Berg, M. L. Zuley, J. H. Sumkin, and S. Wu, “Deep learning to distinguish recalled but benign mammography images in breast cancer screening,” *Clin. Cancer Res.*, vol. 24, no. 23, pp. 5902–5909, Dec. 2018, doi: 10.1158/1078-0432.CCR-18-1115.
- [10] S. Ramadhani and S. R. First, “A Review Comparative Mammography Image Analysis on Modified CNN Deep Learning Method,” *Indones. J. Artif. Intell. Data Min.*, vol. 3, no. 1, pp. 1–10, 2020, doi: 10.24014/ijaidm.v2i2.xxxx.
- [11] Z. Yan, H. Liu, T. Li, J. Li, and Y. Wang, “Two dimensional correlation spectroscopy combined with ResNet: Efficient method to identify bolete species compared to traditional machine learning,” *LWT*, vol. 162, p. 113490, Jun. 2022, doi: 10.1016/j.lwt.2022.113490.
- [12] Z. Niswati, R. Hardatin, M. N. Muslimah, and S. N. Hasanah, “Perbandingan Arsitektur ResNet50 dan ResNet101 dalam Klasifikasi Kanker Serviks pada Citra Pap Smear,” *Fakt. Exacta*, vol. 14, no. 3, p. 160, Oct. 2021, doi: 10.30998/faktorexacta.v14i3.10010.
- [13] S. Showkat and S. Qureshi, “Efficacy of Transfer Learning-based ResNet models in Chest X-ray image classification for detecting COVID-19 Pneumonia,” *Chemom. Intell. Lab. Syst.*, vol. 224, May 2022, doi: 10.1016/j.chemolab.2022.104534.
- [14] Meta AI Research, “WideResNet,” <https://paperswithcode.com/model/wide-resnet?variant=wide-resnet-50-2>, Feb. 2021.
- [15] D. Saranyaraj, M. Manikandan, and S. Maheswari, “A deep convolutional neural network for the early detection of breast carcinoma with respect to hyper- parameter tuning,” *Multimed. Tools Appl.*, vol. 79, no. 15–16, pp. 11013–11038, Apr. 2020, doi: 10.1007/s11042-018-6560-x.
- [16] M. Toğaçar, B. Ergen, and Z. Cömert, “Application of breast cancer diagnosis based on a combination of convolutional neural networks, ridge regression and linear discriminant analysis using invasive breast cancer images processed with autoencoders,” *Med. Hypotheses*, vol. 135, Feb. 2020, doi: 10.1016/j.mehy.2019.109503.
- [17] K. Dembrower et al., “Comparison of a deep learning risk score and standard mammographic density score for breast cancer risk prediction,” *Radiology*, vol. 294, no. 2, pp. 265–272, 2020, doi: 10.1148/radiol.2019190872.
- [18] M. Devarakonda Venkata and S. Lingamgunta, “A Convolution Neural Network based MRI breast mass diagnosis using Zernike moments,” *Mater. Today Proc.*, Jul. 2021, doi: 10.1016/j.matpr.2021.06.133.
- [19] D. Sarwinda, R. H. Paradisa, A. Bustamam, and P. Anggia, “Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer,” in *Procedia Computer Science, Elsevier B.V.*, 2021, pp. 423–431. doi: 10.1016/j.procs.2021.01.025.
- [20] B. M. Sujatmiko, E. Yudaningtyas, and P. M. Raharjo, “Convolutional Neural Network Using ResNet Network Design As Skin Tumor Classification Method,” vol. 11, no. 1, pp. 53–64, 2022.
- [21] A. Ridhovan and A. Suharso, “PENERAPAN METODE RESIDUAL NETWORK (RESNET) DALAM KLASIFIKASI PENYAKIT PADA DAUN GANDUM,” *JIPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 7, no. 1, pp. 58–65, 2022, doi: 10.29100/jipi.v7i1.2410.
- [22] Prajwal Khare, Kalpana Sharma, Sunil Dhimal, and Sital Sharma, 2019 Second International Conference on Advanced Computational and Communication Paradigms (ICACCP). IEEE, 2019.