

**EVALUASI ARSITEKTUR PADA *CONVOLUTIONAL NEURAL NETWORK*
(CNN) UNTUK KLASIFIKASI CITRA PENYAKIT KANKER PAYUDARA**

(Skripsi)

OLEH

ADINDA AULIA SARI

NPM 2117051018



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

**EVALUASI ARSITEKTUR PADA *CONVOLUTIONAL NEURAL NETWORK*
(CNN) UNTUK KLASIFIKASI CITRA PENYAKIT KANKER PAYUDARA**

Oleh

**ADINDA AULIA SARI
NPM 2117051018**

Skripsi

**Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA KOMPUTER**

**Pada Jurusan Ilmu Komputer
Fakultas Matematika dan Ilmu Pengetahuan Alam**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

ABSTRAK

EVALUASI ARSITEKTUR PADA *CONVOLUTIONAL NEURAL NETWORK* (CNN) UNTUK KLASIFIKASI CITRA PENYAKIT KANKER PAYUDARA

OLEH

ADINDA AULIA SARI

Kanker payudara merupakan salah satu penyebab utama kematian pada wanita di seluruh dunia. Deteksi dini melalui citra mammogram menjadi krusial untuk meningkatkan peluang kesembuhan, namun memerlukan metode klasifikasi yang akurat. Dalam studi ini terletak pada belum dilakukannya evaluasi secara komprehensif terhadap performa berbagai arsitektur *Convolutional Neural Network* (CNN) dalam klasifikasi biner, yaitu kelas Normal dan Abnormal serta Jinak dan Ganas, khususnya menggunakan dataset mammogram. Penelitian ini mengimplementasikan dan mengevaluasi tiga arsitektur CNN yaitu ResNet50, VGG16, dan DenseNet201 dengan menggunakan dataset dari Kaggle. Evaluasi dilakukan berdasarkan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil eksperimen menunjukkan bahwa DenseNet201 memberikan performa terbaik pada klasifikasi Normal dan Abnormal dengan akurasi mencapai 92%, sementara ResNet50 menunjukkan hasil paling optimal pada klasifikasi Jinak dan Ganas dengan akurasi sebesar 84%.

Kata Kunci: CNN, Kanker Payudara, DenseNet201, VGG16, ResNet50

ABSTRACT

EVALUTION OF CONVOLUTIONAL NEURAL NETWORK (CNN) ARCHITECTURES FOR BREAST CANCER IMAGE CLASSIFICATION

By

ADINDA AULIA SARI

Breast cancer is one of the leading causes of death among women worldwide. Early detection through mammogram images is crucial to improve the chances of recovery, but it requires accurate classification methods. In this study, the focus is on the lack of comprehensive evaluation of the performance of various Convolutional Neural Network (CNN) architectures in binary classification, namely Normal and Abnormal classes as well as Benign and Malignant, specifically using mammogram datasets. This study implements and evaluates three CNN architectures, namely ResNet50, VGG16, and DenseNet201, using a dataset from Kaggle. The evaluation is based on the metrics of accuracy, precision, recall, and F1-score. The experimental results show that DenseNet201 provides the best performance in the Normal and Abnormal classification with an accuracy of 92%, while ResNet50 shows the most optimal results in the Benign dan Malignant classification with an accuracy of 84%.

Keywords: CNN, Breast Cancer, DenseNet201, VGG16, ResNet50

Judul Skripsi : Evaluasi Arsitektur *Convolutional Neural Network* (CNN) Untuk Klasifikasi Citra Penyakit Kanker Payudara

Nama Mahasiswa : Adinda Aulia Sari

Nomor Pokok Mahasiswa : 2117051018

Jurusan : Ilmu Komputer

Fakultas : Matematika dan Ilmu Pengetahuan Alam

MENYETUJUI

Komisi Pembimbing

Prof. Admi Syarif, Ph.D.
NIP. 196701031992031003

Wartariyus, S.Kom., M.T.I.
NIP. 197301222006041002

Ketua Jurusan Ilmu Komputer FMIPA

Ketua Program Studi

Dwi Sakethi, S.Si., M.Kom.
NIP. 196806111998021001

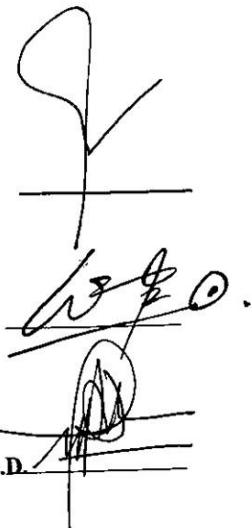
Tristiyanto, M.I.S., Ph.D.
NIP. 198104142005011001

MENGESAHKAN

1. Tim Pengaji

Ketua

: Prof Admi Syarif, Ph.D.



Sekertaris

: Wartariyus, S.Kom., M.T.I.

Pengaji Utama

: Favorisen R. Lumbanraja, Ph.D.



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam

Dr. Eng. Heri Satria, S.Si., M.Si.

NIP. 197110012005011002

Tanggal Lulus Ujian Skripsi: **30 Juli 2025**

PERNYATAAN

Saya yang bertanda tangan dibawah ini:

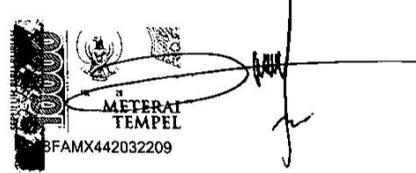
Nama : Adinda Aulia Sari

NPM : 2117051018

Jurusan : Ilmu Komputer

Menyatakan bahwa skripsi saya yang berjudul "**Evaluasi arsitektur pada Convolutional Neural Network (CNN) untuk Klasifikasi Citra Penyakit Kanker Payudara**" merupakan karya saya sendiri dan bukan karya orang lain. Semua tulisan yang tertuang di skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila kemudian hari skripsi ini terbukti hasil jiplakan atau dibuat orang lain, maka saya bersedia menerima sanksi berupa pencabutan gelar yang saya terima.

Bandar Lampung, 12 Agustus 2025
Penulis,



Adinda Aulia Sari
NPM. 2117051018

RIWAYAT HIDUP



Penulis lahir di Tangerang pada tanggal 27 Februari 2003 sebagai anak pertama dari pasangan Bapak Toto Siswanto dan Ibu Maemunah Anggraini Sari. Penulis masuk Pendidikan formal di SD Negeri 1 Wates pada Tahun 2015, kemudian melanjutkan di SMP Negeri 1 Bumi Ratu Nuban dan selesai pada Tahun 2018. Penulis kemudian melanjutkan Pendidikan menengah atas di SMA Negeri 1 Trimurjo dan lulus pada Tahun 2021.

Pada tahun 2021 penulis terdaftar sebagai mahasiswa Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam universitas Lampung melalui jalur SNMPTN. Selama menjadi mahasiswa penulis aktif mengikuti berbagai kegiatan di antaranya sebagai berikut.

1. Menjadi Anggota Printer Himpunan Mahasiswa Ilmu Komputer (Himakom) Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung Tahun 2021.
2. Menjadi Anggota Adapter Himpunan Mahasiswa Ilmu Komputer (Himakom) Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung Tahun 2021.
3. Menjadi Anggota Bidang Internal Himpunan Mahasiswa Ilmu Komputer (Himakom) Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung Tahun 2022.
4. Mengikuti Kerja Praktik di Dinas Perkebunan Provinsi Lampung di bidang Keuangan Tahun 2023
5. Menjadi Asisten dosen Jurusan Ilmu Komputer untuk mata kuliah Pemrograman Web pada Semester Genap Tahun Ajaran 2023/2024.

6. Menjadi Staff Ahli Internal Badan Eksekutif Mahasiswa (BEM) Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung Tahun 2023.
7. Melaksanakan KKN di Desa Bandar Agung 2, Kecamatan Bandar Sribhawono, Kabupaten Lampung Timur Tahun 2024.
8. Mengikuti program Kampus Merdeka Studi Independen Bersertifikat Batch 6 di Celerates alur pembelajaran Web Development & UI/UX Design Tahun 2024.

MOTTO

Sebenarnya tidak ada yang perlu dikhawatirkan, Allah memang tidak menjanjikan hidupmu selalu mudah. Tetapi, dua kali Allah berjanji bahwa:

“Fa inna ma’al - ‘usri yusra, inna ma’al - ‘unsri Yusra”

(Karena sesungguhnya sesudah kesulitan itu pasti ada kemudahan)

(Q.S Al-Insyirah: 05-06)

"Your regrets aren't what you did, but what you didn't do. So take every opportunity."

- Cameron Diaz

“Kita harus selalu bersyukur, ikhlas dan belajar. Hidup adalah perjuangan, hidup adalah bagaimana kita menilai.”

- Jessica Iskandar

PERSEMPAHAN

Alhamdulillahirobbilalamin

Dengan rasa Syukur kepada Allah Subhanahu Wa Ta'ala atas Ridho, Rahmat dan Karunia-Nya sehingga saya dapat menyelesaikan skripsi ini Shalawat serta salam selalu tercurahkan kepada Nabi Muhammad Shallallahu Alaihi Wasallam.

Kupersembahkan karya ini kepada:

Kedua Orang Tuaku Tercinta

Bunda dan Ayah, terima kasih selalu atas doa dan kasih sayang yang tiada terhingga. Terima kasih atas segala dukungan baik moril ataupun materi. Terima kasih atas doa yang tidak pernah Lelah diberikan, terima kasih atas keringat dan air mata. Terima kasih untuk selalu percaya. Terima kasih untuk adik-adikku tersayang atas dukungan dan do'a yang diberikan kepadaku.

Terima kasih juga untuk semua pihak yang terlibat dalam pembuatan skripsi ini.

Semoga Allah senantiasa membalas setiap kebaikan kalian semua.

Almamater Tercinta, Universitas Lampung dan Jurusan Ilmu Komputer

Tempat bernaung mengemban ilmu untuk bekal kehidupan.

SANWACANA

Puji Syukur penulis ucapkan kehadiran Allah Subhanahu Wata'ala, karena atas Rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi ini. Shalawat serta salam semoga senantiasa tercurahkan kepada junjungan Nabi Muhammad Shallallahu Alaihi Wasallam yang penulis harapkan syafaatnya di hari akhir kelak. Skripsi dengan judul "**Evaluasi Arsitektur Convolutional Neural Network (CNN) Untuk Klasifikasi Citra Penyakit kanker Payudara**" adalah salah satu syarat untuk memperoleh gelar sarjana computer pada Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

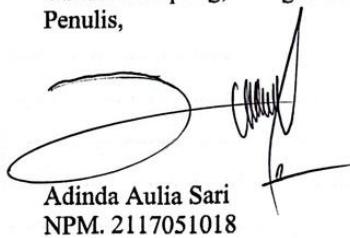
Dalam penyusunan skripsi ini, penulis mendapat bantuan, dukungan dan motivasi dari berbagai pihak. Oleh karena itu penulis mengucapkan terima kasih yang sebesar besarnya kepada:

1. Kedua Orang Tuaku Toto Siswanto dan Maemunah Anggraini Sari, beliau memang tidak sempat merasakan bangku perkuliahan. Namun, beliau kerja keras, memberikan motivasi, memberikan dukungan sehingga penulis mampu menyelesaikan masa program studi ini sampai selesai. Terima kasih karena tidak pernah meragukan anak perempuanmu ini, selalu mengusahakan apapun dan tidak pernah menganggap anak yang lemah.
2. Bapak Dr.Eng. Heri Satria, S.Si., M.Si., Selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
3. Bapak Dwi Sakethi, S.Si., M.Kom., Selaku Ketua Jurusan Ilmu Komputer FMIPA Universitas Lampung.
4. Ibu Yunda Heningtyas, M.Kom., Selaku Sekretaris Jurusan Ilmu Komputer FMIPA Universitas Lampung.
5. Dwi Sakethi, S.Si., M.Kom., Selaku Ketua Jurusan Ilmu Komputer FMIPA Universitas Lampung.

6. Ibu Yunda Heningtyas, M.Kom., Selaku Sekretaris Jurusan Ilmu Komputer FMIPA Universitas Lampung.
7. Bapak Tristiyanto, S.Kom., M.I.S., Ph.D., Selaku Kepala Prodi S1 Ilmu Komputer FMIPA Universitas Lampung.
8. Bapak M. Iqbal Parabi, S.Si., M.T., Selaku Dosen Pembimbing Akademik yang telah memberikan motivasi dan saran kepada penulis.
9. Bapak prof. Admi Syarif, Ph.D., Selaku Dosen Pembimbing Utama yang selalu membimbing, memberikan arahan, motivasi, masukan serta saran dalam penyelesaian skripsi ini.
10. Bapak Wartariyus, S.Kom., M.T.I., Selaku Dosen Pembimbing Kedua yang selalu membimbing, memberikan arahan, motivasi, masukan serta saran dalam penyelesaian skripsi ini.
11. Bapak Favorisen R. Lumbanraja, Ph.D., Selaku Dosen Pembahas yang telah memberikan saran dan masukan bermanfaat dalam perbaikan skripsi ini.
12. Bapak, Ibu Dosen dan semua Staf Jurusan Ilmu Komputer FMIPA Universitas Lampung yang telah memberikan banyak ilmu dan wawasan baru kepada penulis dan telah membantu segala urusan administrasi yang penulis butuhkan.
13. Kedua adikku Dani dan Juna yang telah mendukung, memberikan do'a dan semangat kepada penulis. Tumbuhlah menjadi versi paling hebat, Adik-adikku.
14. Teman-teman seperjuangan semasa kuliah "YTTA" Nur Fitri, Shela Rana, Shafira Andaya, Ferisna, Retno Lestari, Aninda Revi, Osmycin dan teman lainnya yang tidak bisa penulis sebutkan satu persatu, terima kasih karena selalu ada, selalu support dan saling membantu serta mewarnai hari-hari penulis selama masa perkuliahan.
15. Teman-teman "Until S.Kom" Amelia Agustina dan Nurul Fadillah yang sudah menemani, berproses, mendukung serta memotivasi penulis.
16. Ibu, Bapak dan Kakak-kakak seerbimbingan, Ibu Apri, Bu Lilis, Pak Rico, Pak Nizar, Pak Nurjoko, Pak Putra, Kak Safiira, Kak Joy, Kak Arman, Kak Nabila, Kak Yoan yang telah memberikan bantuan, masukan, dukungan dan menemani selama proses pengerjaan skripsi.

17. Sahabat tercinta Intan Qhori Janati yang selalu mendukung dan memberikan do'a dan semangat kepada penulis.
18. Teman- teman Ilmu Komputer Angkatan 2021 yang menjadi teman satu Angkatan selama menjalankan masa studi.
19. Terakhir, untuk diri sendiri yang telah berjuang sejauh ini. Terima kasih telah bertahan, terus belajar dan tidak pernah benar-benar berhenti. Semoga apa yang telah diperjuangkan menjadi jalan untuk memberi arti, baik bagi diri sendiri maupun orang lain.

Bandar Lampung, 12 Agustus 2025
Penulis,



Adinda Aulia Sari
NPM. 2117051018

DAFTAR ISI

DAFTAR TABEL	vi
DAFTAR GAMBAR.....	viii
I. PENDAHULUAN	1
1.2. Rumusan Masalah	3
1.3. Batasan Masalahs	4
1.4. Tujuan Penelitian.....	4
1.5. Manfaat Penelitian.....	4
II. TINJAUAN PUSTAKA	5
2.1. Penelitian Terdahulu.....	5
2.2. Kanker Payudara	6
2.3. <i>Artificial Intellingence</i>	10
2.4. <i>Machine Learning</i>	11
2.4.1. <i>Supervised Learning</i>	12
2.4.2. <i>Unsupervised Learning</i>	12
2.4.3. <i>Reinforcement Learning</i>	13
2.5. <i>Deep Learning</i>	13
2.6. <i>Convolutional Neural Network (CNN)</i>	14
2.6.1. <i>Convolutional Layer</i>	15
2.6.2. <i>Rectified Linear Unit (ReLU)</i>	16
2.6.3. <i>Polling Layer</i>	16
2.6.4. <i>Fully Connected Layer</i>	17
2.7. Arsitektur ResNet50	18
2.8. Arsitektur <i>Visual Geometry Group</i> (VGG-16)	19
2.9. Arsitektur denseNet201	20
2.10. <i>Google Collaboratory</i>	21
2.11. <i>Image Augmentation</i>	21
2.12. <i>Confusion Matrix</i>	21

III. METODOLOGI PENELITIAN.....	24
3.1. Tempat dan Waktu Penelitian	24
3.2. Alat dan Bahan	25
3.2.1. <i>Hardware</i>	25
3.2.2. Software.....	25
3.2.3. <i>Library</i>	25
3.3. Tahapan Penelitian.....	27
3.3.1. Akuisisi Data.....	28
3.3.2. <i>Pre-Processing</i>	29
3.4. Modelling	32
3.5. Evaluasi	33
IV.KESIMPULAN DAN SARAN.....	34
5.1. Kesimpulan.....	34
5.2. Saran.....	35
V.DAFTAR PUSTAKA	36

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu Terkait Penelitian ini.....	5
2. <i>Confusion Matrix</i>	22
3. Waktu Penelitian.....	24
4. Skenario <i>Balanced</i> 1.....	30
5. Skenario <i>Balanced</i> 2.....	30
6. Pembagian Data (80%:10%:10%) Skema 1	31
7. Pembagian Data (70%:15%:15%) Skema 1	31
8. Pembagian Data (80%:10%:10%) Skema 2	32
9. Pembagian Data (70%:15%:15%) Skema 2	32
10. Distribusi Kelas 1	34
11. Distribusi Kelas 2	34
12. Augmentasi Data Skema 1	35
13. Augmentasi Data Skema 1	35
14. Skenario Pembagian Data 1	37
15. Skenario Pembagian Data 2	37
16. <i>Hyperparameter</i> pada CNN	37
17. Evaluasi Hasil Akurasi DenseNet201 Kelas (Normal dan Abnormal)	40
18. Evaluasi Hasil Akurasi DenseNet201 Kelas (Jinak dan Ganas).....	42
19. Evaluasi Hasil Akurasi VGG16 Kelas (Normal dan Abnormal)	44
20. Evaluasi Hasil Akurasi VGG16 Kelas (Jinak dan Ganas).....	46
21. Evaluasi Hasil Akurasi ResNet50 Kelas (Normal dan Abnormal)	48
22. Evaluasi Hasil Akurasi ResNet50 Kelas (Jinak dan Ganas).....	49
23. Perbandingan Akurasi Kelas Normal dan Abnormal.....	51

24. Perbandingan Akurasi Kelas Jinak dan Ganas.....	52
---	----

DAFTAR GAMBAR

Gambar	Halaman
1. Jumlah Kanker di Indonesia	9
2. Jumlah Insiden dan Kematian pada Kanker	9
3. Perbandingan Kematian Berdasarkan Jenis Kelamin pada Kanker	10
4. Jenis <i>Machine Learning</i>	12
5. Struktur <i>Neural Network</i> pada <i>Deep learning</i>	13
6. Arsitektur Algoritma CNN	14
7. Ilustrasi Operasi Konvolusi	15
8. <i>Rectified Linear Unit (ReLU)</i>	16
9. <i>Polling Layer</i>	17
10. <i>Fully Connected Layer</i>	17
11. Arsitektur ResNet50	18
12. Arsitektur VGG-16.....	19
13. Arsitektur DenseNet201	20
14. Alur Kerja Penelitian	27
15. Payudara Jinak.....	28
16. Payudara Ganas	28
17. Payudara Normal.....	29
18. Alur <i>Preprocessing</i> Data.....	29
19. Horizontal <i>Flip</i>	36
20. Vertikal <i>Flip</i>	36
21. <i>Rotation</i> 90	36
22. <i>Rotation</i> 270	36

23. <i>Layer</i> Arsitektur DenseNet201	38
24. <i>Layer</i> Arsitektur VGG16	39
25. <i>Layer</i> Arsitektur ResNet50.....	40
26. <i>Confusion Matrix</i> DenseNet201 Skema 1 Kelas Normal dan Abnormal	41
27. <i>Confusion Matrix</i> DenseNet201 Skema 2 Kelas Normal dan Abnormal	42
28. <i>Confusion Matrix</i> DenseNet201 Skema 1 Kelas Jinak dan Ganas.....	43
29. <i>Confusion Matrix</i> DenseNet201 Skema 2 Kelas Jinak dan Ganas.....	43
30. <i>Confusion Matrix</i> VGG16 Skema 1 Kelas Normal dan Abnormal	45
31. <i>Confusion Matrix</i> VGG16 Skema 2 Kelas Normal dan Abnormal	45
32. <i>Confusion Matrix</i> VGG16 Skema 1 Kelas Jinak dan Ganas.....	46
33. <i>Confusion Matrix</i> VGG16 Skema 2 Kelas Jinak dan Ganas.....	47
34. <i>Confusion Matrix</i> ResNet50 Skema 1 Kelas Normal dan Abnormal	48
35. <i>Confusion Matrix</i> ResNet50 Skema 2 Kelas Normal dan Abnormal	49
36. <i>Confusion Matrix</i> ResNet50 Skema 1 Kelas Jinak dan Ganas.....	50
37. <i>Confusion Matrix</i> ResNet50 Skema 2 Kelas Jinak dan Ganas.....	50
38. Evaluasi Skema 1 Perbandingan Normal Abnormal	52
39. Evaluasi Skema 2 Perbandingan Normal Abnormal	52
40. Evaluasi Skema 1 Perbandingan Jinak Ganas	53
41. Evaluasi Skema 2 Perbandingan Jinak Ganas	53
42. <i>Test Case</i> Cancer	54
43. <i>Test Case</i> Benign	55
44. <i>Test Case</i> Paru-Paru.....	55
45. <i>Test Case</i> Daun Bayam.....	55

I. PENDAHULUAN

1.1. Latar Belakang

Kanker payudara adalah salah satu penyakit yang paling umum diderita bagi para wanita diseluruh dunia. Pertumbuhan jaringan payudara yang tidak normal dan tidak teratur yang kemudian berkembang menjadi struktur yang menyerupai tumor, dikenal sebagai kanker payudara (Khan et al., 2022). Berdasarkan data Globocan tahun 2020, lebih dari 396.914 kasus kanker terjadi di Indonesia, kanker payudara menempati peringkat pertama dengan jumlah kasus 68.858 atau 16,6% dari total kanker yang terjadi di Indonesia (Rizaty, 2021).

Prediksi yang akurat terhadap kanker payudara sangat penting untuk menentukan pengobaan yang tepat dan meningkatkan kelangsungan hidup pasien. Namun, proses diagnosis secara manual membutuhkan analisis terhadap data yang kompleks dan dalam jumlah besar, tentu menjadi tantangan besar bagi tenaga medis. Oleh karena itu, sistem berbasis komputer mulai banyak digunakan untuk membantu proses klasifikasi penyakit, termasuk kanker payudara, seiring dengan berkembangnya teknologi *Artificial Intelligence* (AI).

Artificial Intelligence (AI) memiliki kinerja yang baik untuk meningkatkan konsistensi dan efisiensi dalam pemeriksaan medis, serta mengurangi angka kesalahan diagnosis (Pacilè et al., 2020). Penerapan AI dapat membantu mengurangi jumlah negatif palsu dan positif palsu kanker payudara. Hal ini dikarenakan AI tidak terpengaruh oleh subjektivitas dan dapat mengurangi beban kerja ahli radiologi sebesar 88% dengan penurunan waktu baca tiap kasus mencapai 11%. Implementasi pada AI dapat meningkatkan akurasi yang baik dalam mamografi (J. Liu et al., 2023).

Salah satu algoritma pembelajaran mesin yang digunakan untuk pengenalan gambar adalah *Convolutional Neural Network* (CNN). CNN secara otomatis menganalisis citra visual dari gambar dengan mengoptimalkan filter atau kernel. Seperti Namanya, konsep utama dari CNN adalah operasi convolusi, dimana filter diterapkan pada gambar masukan. Ini membantu dalam pengenalan pola pada lapisan yang lebih dalam (Busaleh et al., 2021). Metode *Convolutional Neural Network* (CNN) mempunyai potensi untuk menghasilkan hasil yang menguntungkan yang berkaitan sehingga meningkatkan kemampuan dalam diagnosis (Ulagamuthalvi et al., 2022).

Beberapa metode seperti mammografi, dan pemeriksaan histopatologi dapat digunakan untuk memeriksa kanker payudara melalui citra medis. Meskipun histopatologi masih dilakukan secara manual oleh ahli patologi dengan mempertimbangkan skor tingkat keparahan kanker, ini merupakan pemeriksaan baku emas dalam penegakan diagnosis kanker payudara (Matos Jr., 2019). Untuk meningkatkan peluang kesembuhan, deteksi dini sangat penting, tetapi pendekatan tradisional sering kali tidak cukup akurat untuk menemukan tumor ganas pada tahap awal (Dyanti & Suariyani, 2016).

Studi sebelumnya menunjukkan bahwa CNN dapat mendeteksi kanker payudara lebih akurat daripada pendekatan konvensional (Spanhol et al., 2016). Penelitian (Cahya et al., 2021) menggunakan AlexNet dan menunjukkan bahwa arsitekturnya dalam Klasifikasi kanker mata menggunakan AlexNet mendapatkan akurasi 98.37%. Penelitian (Fauzan Novriandy et al., 2024) menggunakan gambar histopatologi payudara yang diperoleh dari dataset publik, berhasil mencapai akurasi sebesar 96% dalam klasifikasi kanker mulut menggunakan arsitektur DenseNet201. Dataset harus terdiri dari gambar kanker mulut yang jelas dan detail, sehingga model dapat belajar pola unik dari setiap gambar. Penelitian sebelumnya telah menggunakan struktur CNN alternatif seperti arsitektur VGG-16. Penelitian (Idawati et al., 2024) mengevaluasi kinerja model dalam klasifikasi kanker payudara dengan menggunakan struktur ini. Hasil evaluasi menunjukkan bahwa model VGG-16 mencapai akurasi 78,87% berdasarkan metrik *accuracy*, *precision*, *recall*, *score F1*.

Namun, tantangan utama dalam klasifikasi kanker payudara adalah keberagaman jenis tumor yang dapat muncul. Tiga kategori utama tumor payudara adalah *Benign* (jinak), *Malignant* (ganas) dan Normal. Untuk menilai efektivitas model CNN dalam klasifikasi tersebut, dilakukan dua skema pengujian. Pada klasifikasi pertama yaitu Normal dan Abnormal, yang tujuannya untuk mendeteksi awal adanya kelainan, dan klasifikasi kedua yaitu Jinak dan Ganas, yang berfokus pada tingkat keganasan tumor (Spanhol et al., 2016). Untuk menilai kinerja model CNN dalam klasifikasi kanker payudara yaitu dengan metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *score F1* akan digunakan. Dengan menggunakan metrik evaluasi ini, kami dapat mengetahui seberapa baik model mampu membedakan antara citra Normal, Jinak dan Ganas (K. Liu et al., 2018).

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi kanker payudara menggunakan arsitektur CNN dengan berbagai arsitektur seperti ResNet-50, VGG-16, dan DenseNet201. Selain itu, untuk menyalakan kinerja masing-masing arsitektur dalam klasifikasi kanker payudara agar dapat memilih model yang paling efektif (Diwakaran & Surendran, 2023). Diharapkan bisa memberikan rekomendasi secara lebih lanjut dalam mendeteksi penyakit kanker payudara dengan *Deep Learning*, serta mengevaluasi arsitektur CNN untuk mengetahui arsitektur yang paling efektif (Cruz-Roa et al., 2014).

1.2. Rumusan Masalah

Adapun rumusan masalah pada penelitian ini adalah sebagai berikut.

1. Bagaimana implementasi arsitektur CNN seperti ResNet50, VGG16 dan DenseNet201 dalam klasifikasi citra kanker payudara?
2. Bagaimana kinerja masing-masing arsitektur CNN dalam dua skema klasifikasi, yaitu normal dan Abnormal serta Jinak dan Ganas?
3. Arsitektur CNN mana yang paling efektif dan akurat dalam membantu deteksi kanker payudara berdasarkan hasil evaluasi metrik klasifikasi?

1.3. Batasan Masalah

Adapun Batasan masalah pada penelitian ini adalah sebagai berikut.

1. Penelitian ini hanya akan menggunakan citra Mammogram sebagai masukkan data untuk arsitektur CNN.
2. Fokus penelitian terbatas meliputi arsitektur CNN yaitu ResNet50, VGG-16, DenseNet201.
3. Dataset yang digunakan ada 2 skema yaitu Normal dan Abnormal serta Jinak dan Ganas.

1.4. Tujuan Penelitian

Adapun rumusan masalah pada penelitian ini adalah sebagai berikut.

1. Mengimplementasikan arsitektur CNN dalam klasifikasi citra kanker payudara.
2. Mengevaluasi performa arsitektur CNN dalam dua skema yaitu Normal dan Abnormal serta Jinak dan Ganas.
3. Menentukan arsitektur CNN yang paling optimal dan akurat untuk digunakan dalam sistem deteksi kanker payudara.

1.5. Manfaat Penelitian

Adapun manfaat penelitian ini adalah sebagai berikut.

1. Mengetahui perbandingan kinerja arsitektur CNN dalam klasifikasi kanker payudara.
2. Memberikan kontribusi ilmiah dalam pengembangan sistem klasifikasi citra kanker payudara berbasis *deep learning*.
3. Memberikan rekomendasi untuk pengembangan lebih lanjut dari arsitektur *Convolutional Neural Network* (CNN) dalam klasifikasi citra kanker payudara secara efektif.

II. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Terdapat beberapa penelitian terdahulu yang berhubungan dengan penelitian ini yang diuraikan dalam Tabel 1.

Tabel 1. penelitian Terdahulu terkait penelitian ini.

Judul	Metode	Data	Akurasi
Diagnosis penyakit kanker payudara menggunakan metode K-Means Clustering (Susilowati et al., 2019).	K-Means	Data diambil dari UCI Machine Learning sebanyak 569. Memiliki 2 kelas yaitu ganas 358 dan jinak 212 data.	Akurasi 82.93%
Klasifikasi kanker payudara dan prediksi label kelas menggunakan ResNet50 (Kumar et al., 2023).	ResNet 50	Data yang digunakan adalah CBIS-DDSM (<i>Curated Breast Imaging Subset Of DDSM</i>) yang terdiri dari gambar mamografi dari pasien kanker payudara.	Akurasi 90.6%
Klasifikasi penyakit kanker payudara menggunakan K Nearest Neighbor (Atthalla et al., 2018).	KNN	Dataset diambil dari Sklearn yang memiliki 30 atribut dan 569 baris.	Akurasi 93%
<i>Multi -class Breast Cancer Clasification Using CNN Features Hybridization</i> (Chakravarthy et al., 2024).	CNN dan R-CNN	Dataset diambil dari MIAS dan CBIS-DDSM yang memiliki 2 kelas yaitu normal dan abnormal dengan total 322 data.	CNN 91.26% R-CNN 63.89%
Identifikasi jenis rempah Indonesia dengan CNN menggunakan arsitektur VGG-16 (Maulana et al., 2024).	VGG16	Dataset diambil dari website Kaggle terdiri dari 31 folder yang berjumlah 31 kelas dengan masing-masing kelas berjumlah 210 citra.	Akurasi 86.66%

Judul	Metode	Data	Akurasi
Klasifikasi citra pada penyakit kanker mulut menggunakan arsitektur DenseNet201 menggunakan optimasi ADAM dan SGD (Fauzan Novriandy et al., 2024).	DenseNet201	Dataset diambil dari gambar histopalogi yang terdiri dari 2 kelas, yaitu normal dan abnormal dengan total 5000 data.	Akurasi 96%
Klasifikasi kanker payudara dari USG gambar menggunakan transfer berbasis model VGG16 (Hossain et al., 2023).	VGG-16	Dataset diambil dari Kaggle yang terdiri dari 13 payudara normal, 437 jinak dan 210 ganas.	Akurasi 91%

2.2. Kanker Payudara

Setiap orang memiliki payudara, baik laki-laki maupun perempuan; payudara laki-laki hanya rudimenter dan tidak berfungsi, sedangkan payudara perempuan tumbuh dan sangat penting untuk reproduksi dan kecantikan (Bustan, 2007). Payudara adalah organ tubuh yang terdiri dari jaringan kelenjar seperti jaringan payudara, lemak, dan jaringan ikat (Anggorowati, 2013). Payudara memiliki peran penting dalam hidup karena membantu mereproduksi kelenjar kulit. Bisa mempengaruhi hormon *estrogen* dan *progesterone*, karena kelenjar susu sebagian besar tumbuh. Ada di atas otot dada dan di bawah kulit (Ariani, 2015).

Kanker adalah benjolan yang terus membesar karena pertumbuhan sel yang tidak terkendali secara abnormal. Kanker dapat berupa Jinak dan Ganas. Kanker Ganas dapat bertumbuh tanpa henti dan dapat *bermetastasis* ke jaringan atau organ lain. Sebaliknya, Kanker Jinak dapat bertumbuh besar, tetapi pertumbuhannya terkontrol dan terbatas, dan tidak *bermetastasis*. Kanker payudara dapat berkembang di sekitar kelenjar susu (Wiliyanarti, 2021). Ini dapat merusak jaringan dan menyebar ke tempat lain (Arafah & Notobroto, 2018).

Menurut Amerika Cancer Society tahun (2016), kanker payudara adalah salah satu kanker yang paling ditakuti oleh Wanita setelah kanker serviks, karena sejumlah sel

di jaringan payudara tumbuh, kehilangan kontrol, dan berkembang dengan cepat. Oleh karena itu, kanker payudara adalah tumor ganas yang berasal dari jaringan dan kelenjar di sebelah luar rongga dada.

Kanker payudara dapat diklasifikasikan menjadi tiga kategori utama yaitu jinak, ganas, dan normal. Kanker jinak tidak memiliki potensi untuk menyebar ke bagian tubuh lain dan biasanya memiliki pertumbuhan yang terkontrol. Contoh kanker payudara jinak termasuk *fibroadenoma* dan *papiloma intraduktal*, yang sering dijumpai pada wanita muda. Sebaliknya, kanker payudara ganas ditandai dengan pertumbuhan sel yang tidak terkontrol dan kemampuan untuk menyebar ke jaringan atau organ lain. Kanker ini dapat berupa karsinoma duktal invasif atau karsinoma lobular invasif.

Menurut penelitian (Spanhol et al., 2016), deteksi dini kanker payudara ganas sangat penting karena dapat meningkatkan peluang kesembuhan. Kanker ganas sering kali memerlukan penanganan medis yang lebih agresif, termasuk pembedahan, kemoterapi, dan radioterapi.

Ada beberapa gejala awal kanker payudara sebagai berikut.

a. Munculnya benjolan di payudara

Benjolan di payudara atau ketiak yang muncul setelah menstruasi sering kali merupakan gejala awal kanker payudara. Benjolan kanker payudara biasanya tidak sakit, tetapi beberapa penderita mungkin merasa sangat sakit. Bentuk benjolan yang keras atau tidak terasa di sisi lain payudara biasanya merupakan indikasi tumor jinak atau kanker payudara (Savitri et al., 2015).

b. Munculnya benjolan di ketiak

Benjolan kecil dan keras di ketiak dapat menunjukkan bahwa kanker payudara telah menyebar ke kelenjar getah bening. Meskipun benjolan ini kecil, mereka sering menyebabkan rasa sakit (Savitri et al., 2015).

c. Perubahan bentuk dan ukuran payudara

Payudara mungkin berubah bentuk dan ukuran, menjadi lebih kecil atau lebih besar atau mungkin tampak menurun (Savitri et al., 2015).

d. Keluarnya cairan di putting susu

Dikenal sebagai keluarnya puting susu: Jika puting susu ditekan, biasanya akan keluar cairan. Namun, jika cairan keluar tanpa menekan puting susu, hanya pada salah satu payudara, dan disertai dengan darah atau nanah berwarna kuning atau hijau, itu bisa menjadi tanda kanker payudara (Savitri et al., 2015).

e. Perubahan pada putting susu

Puting susu mungkin tertarik (retraksi), berubah bentuk atau posisinya, menjadi merah atau berkerak, rasanya seperti terbakar, gatal, dan muncul luka yang sulit dan susah untuk sembuh. Selain itu, kerak, bisul, atau sisik pada puting dapat merupakan gejala kanker payudara yang terjadi tidak umum (Savitri et al., 2015).

f. Kerutan pada kulit payudara

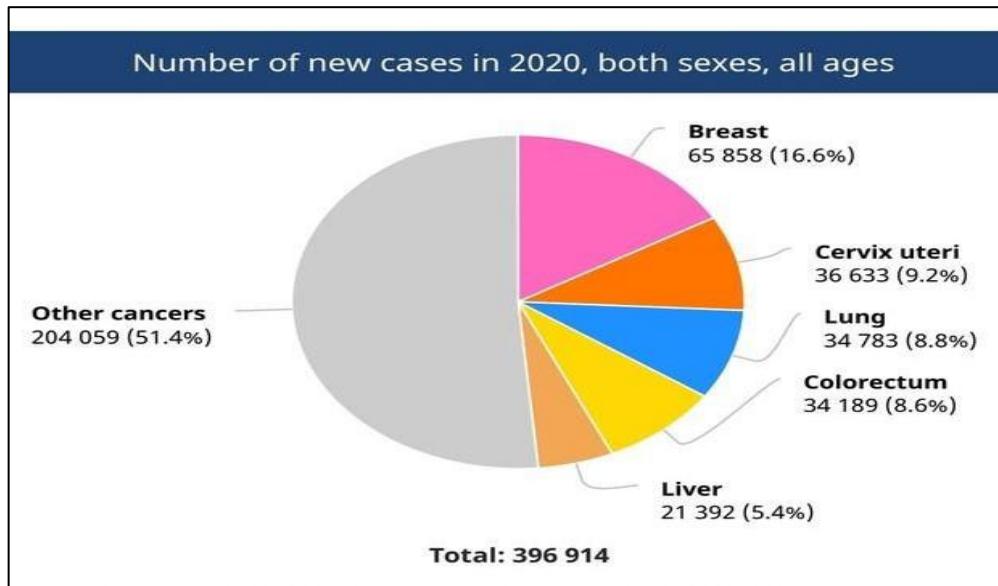
Kerutan yang menyerupai kulit jeruk muncul pada area payudara dan payudara, yang memerah dan menimbulkan rasa panas (Savitri et al., 2015).

g. Tanda-tanda kanker telah menyebar

Pada tahap lanjut, tanda-tanda seperti nyeri tulang, bengkak di lengan atau luka di kulit, penumpukan cairan di sekitar paru-paru (efusi pleura), mual, kehilangan nafsu makan, penurunan berat badan, penyakit kuning, sesak nafas, atau penglihatan ganda dapat muncul (Savitri et al., 2015).

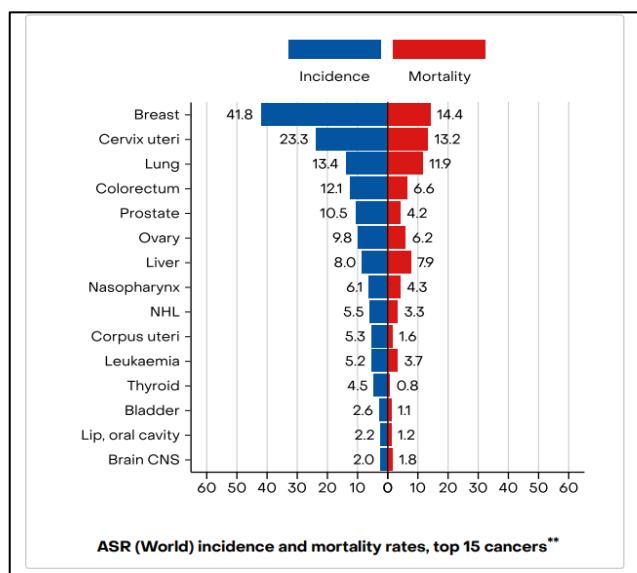
Menurut P2PTM Kemenkes RI (2019), gejala awal kanker payudara diantaranya.

- a. Benjolan di payudara yang seringkali tidak nyeri.
- b. Kulit payudara mengalami perubahan struktur, sehingga tampak mengeras dengan permukaan yang menyerupai kulit jeruk.
- c. Luka pada payudara tidak sembuh dalam waktu yang lama.
- d. Cairan berwarna kuning seperti nanah yang keluar di putih payudara.
- e. Kulit payudara menunjukkan cekungan atau tarikan.

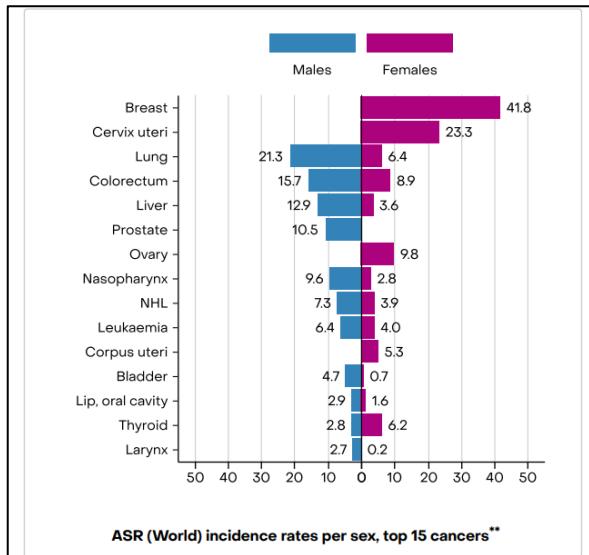


Gambar 1. Jumlah Kanker di Indonesia (Globocan, 2020).

Pada Gambar 1 menunjukkan bahwa data di dunia dengan jumlah penyakit kanker tahun 2020 mencapai 396.914 kasus, yang terdiri dari beberapa jenis kanker seperti kanker payudara sebanyak 65.858 (16.6%), kanker serviks sebanyak 36.633 (9.2%), kanker paru-paru sebanyak 34.783 (8.8%), kanker kolorektal sebanyak 34.189 (8.6%), kanker hati sebanyak 21.392 (5.4%) serta kanker lainnya 51.4%.



Gambar 2. Jumlah Insiden dan Kematian pada Kanker (Globocan, 2020).



Gambar 3. Perbandingan kematian berdasarkan jenis kelamin pada kanker (Globocan, 2020).

Pada Gambar 2 dan 3 menunjukkan total insiden pada penyakit kanker berdasarkan jenis kelamin, yaitu kanker payudara menjadi urutan pertama dan paling tinggi daripada kanker lainnya dengan jumlah 41.8% yang menyerang Perempuan di dunia. Serta kanker payudara menjadi urutan paling mematikan bagi Perempuan di dunia dengan jumlah 41.8%.

2.3. Artificial Intelligence

Artificial Intelligence adalah teknologi yang memungkinkan analisis dan pemahaman pola-pola kompleks dalam data yang sulit dipahami oleh manusia. *Artificial Intelligence* memberikan kemampuan untuk mengidentifikasi dan bertindak berdasarkan wawasan yang mungkin tidak dapat diakses oleh pikiran manusia. Dengan menggunakan algoritma *Artificial Intelligence*, organisasi dapat mengekstrak informasi berharga dari volume data yang besar, yang membantu dalam mendeteksi curang dan pola yang tidak biasa (Gupta, 2023). *Artificial Intelligence* terdiri dari berbagai sub bidang, di antaranya yaitu *Machine Learning* yang berfokus pada kemampuan mesin untuk belajar dari data dan meningkatkan kinerjanya tanpa diprogram secara eksplisit. *Natural Language Processing* (NLP) yang memungkinkan mesin untuk memahami 18 bahasa, dan menghasilkan

bahasa manusia. *Computer Vision* yang memungkinkan mesin untuk menafsirkan dan memahami informasi visual, sub bidang ini biasa digunakan dalam pengenalan gambar dan video, deteksi objek, dan analisis gambar medis. Selain itu, terdapat sub bidang *Pattern Recognition* yaitu proses mengidentifikasi pola atau struktur dalam data, biasa digunakan untuk pengenalan wajah, pengenalan suara, dan analisis gambar (Parisi, 2018).

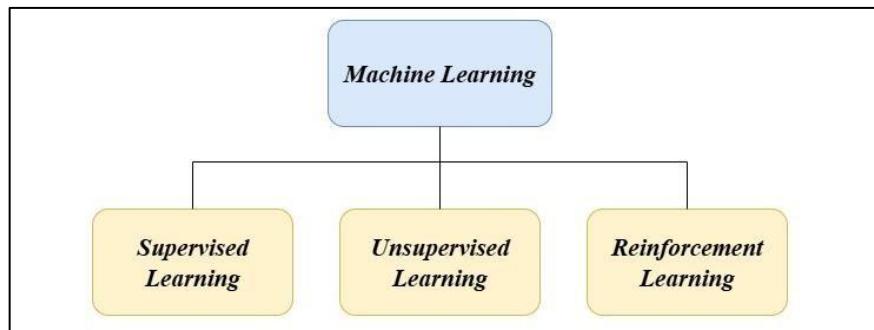
Kecerdasan Buatan diciptakan dengan tujuan untuk mempermudah pekerjaan manusia sehingga menjadi lebih efektif dan efisien. Saat ini, *Artificial Intelligence* telah diaplikasikan di semua sektor kehidupan, termasuk pendidikan, kesehatan, bisnis dan keuangan, transportasi, keamanan, dan sektor-sektor penting lainnya. Dibidang kesehatan, *Artificial Intelligence* digunakan untuk membantu mendiagnosis penyakit dan memprediksi hasil kesehatan pasien. Di bidang bisnis dan keuangan, *Artificial Intelligence* digunakan untuk mendeteksi kecurangan, serta digunakan untuk melakukan perdagangan atau alat transaksi seperti perbankan digital (Parisi, 2018).

Meskipun *Artificial Intelligence* memiliki banyak manfaat dalam membantu kehidupan manusia, *Artificial Intelligence* juga memiliki banyak kelemahan, terutama pada masalah resiko keamanan dan privasi. Masalah privasi ini telah menjadi banyak perhatian, karena *Artificial Intelligence* sering kali membutuhkan akses ke data pribadi agar dapat berfungsi dengan baik. Risiko keamanan juga menjadi perhatian karena *Artificial Intelligence* dapat disalahgunakan untuk tujuan yang tidak baik.

2.4. Machine Learning

Machine Learning atau *ML* adalah suatu implementasi *Artificial Intelligence* (AI) yang memungkinkan sebuah sistem belajar kumpulan data dan melakukan tugas tertentu tanpa diprogram secara *eksplisit* (Mahesh, 2020). Menurut (Rebala et al., 2019), pembelajaran mesin adalah bidang yang ada di Ilmu Komputer mempelajari algoritma untuk memecahkan masalah yang sulit dan kompleks dengan

menggunakan teknik pemrograman tradisional. Algoritma pembelajaran mesin mencari pola tertentu di semua kumpulan data atau semua data untuk membuat aturan.



Gambar 4. Jenis *Machine Learning* (Fran ois-Lavet et al., 2018).

Pada Gambar 4 menunjukkan teknik pembelajaran mesin dibagi menjadi tiga kategori berdasarkan metode pembelajarannya (Syamsul Arifin, 2023). Berikut ini penjelasan untuk setiap jenis *Machine Learning*.

2.4.1. *Supervised Learning*

Dengan memanfaatkan contoh yang tersedia, *supervised learning* adalah teknik pembelajaran mesin yang memetakan data masukan dan keluaran. Dataset masukan terdiri dari data latih dan data uji, yang masing-masing memiliki variabel keluaran yang harus diprediksi atau diklasifikasi. Metode ini akan menerapkan pola dari dataset latih ke setiap dataset uji untuk melakukan prediksi atau klasifikasi variabel keluarannya.

2.4.2. *Unsupervised Learning*

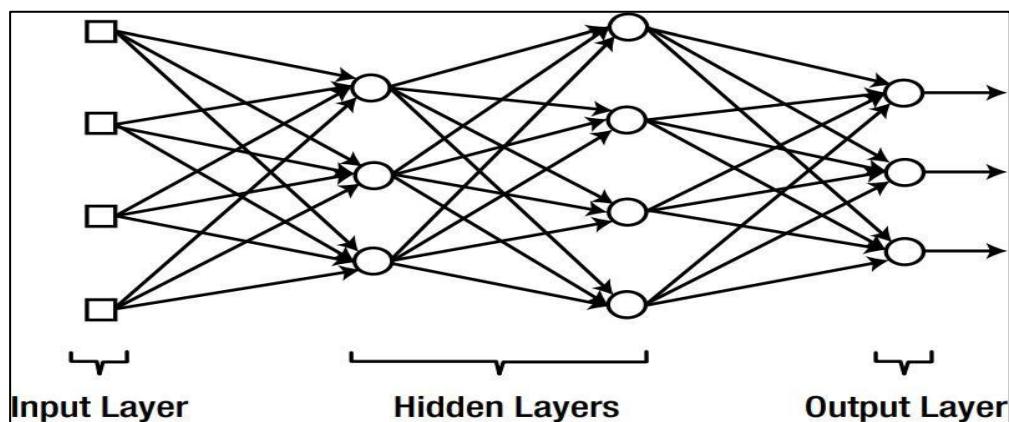
Unsupervised learning merupakan metode pembelajaran mesin yang tidak diawasi melakukan pengelompokan data tanpa pengawasan, yang berarti dataset yang dikelola tidak diberi label tertentu. Metode ini akan dieksplorasi data dalam proses untuk mengidentifikasi strukturnya. (Caron et al., 2018) menyatakan bahwa metode estimasi kepadatan dan reduksi dimensi yang digunakan dalam visi komputer menghasilkan berbagai komponen fitur visual.

2.4.3. Reinforcement Learning

Salah satu metode *machine learning* yang dikenal sebagai *reinforcement learning* adalah menggunakan pengambilan keputusan berurutan untuk mencapai hasil yang optimal. Metode ini mempelajari tentang struktur data secara bertahap untuk memperoleh perilaku dan keterampilan baru (Fran ois-Lavet et al., 2018). Dalam prosesnya, pengalaman coba-coba digunakan sebagai sumber *reward*.

2.5. Deep Learning

Deep Learning juga dikenal sebagai pembelajaran mendalam, adalah subbidang khusus dari pembelajaran mesin yang memanfaatkan algoritma jaringan syaraf tiruan, untuk mempelajari representasi data yang sangat besar. Model jaringan syaraf, yang terdiri dari lapisan literal yang ditumpuk secara terstruktur, digunakan untuk mempelajari lapisan representasi (Pramesty, 2018). Dalam pembelajaran mendalam, terdapat tiga lapisan utama yaitu *input layer*, *hidden layer*, dan *output layer*. Berikut ini adalah gambar lapisan arsitektur jaringan *Deep Learning*.



Gambar 5. Struktur Neural Network pada Deep Learning (Nima & Shila, 2020).

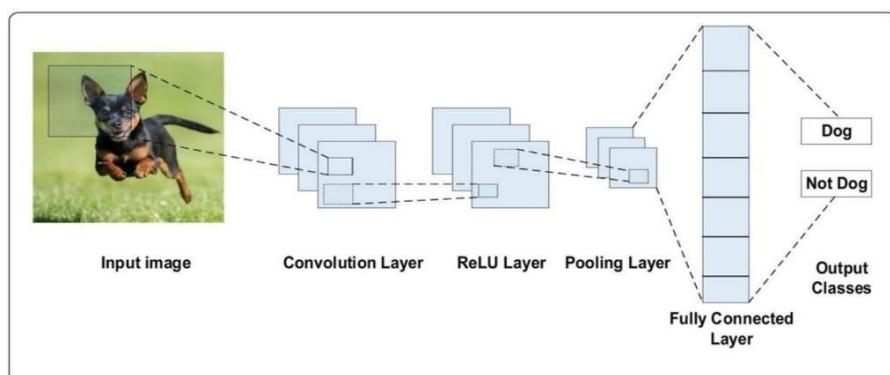
Pada Gambar 5 merupakan arsitektur *deep learning* yang dikenal sebagai perangkat *multilayer*. Arsitektur ini terdiri dari empat node *neuron* pada lapisan *input* (lapisan masukan), yang berfungsi sebagai jalur untuk mengirimkan sinyal masukan ke node berikutnya, dua lapisan tersembunyi berfungsi sebagai perantara antara lapisan *input* dan lapisan *output*, dan tiga node *neuron* pada lapisan keluaran merupakan hasil dari *neural network*.

Performa *deep learning* sangat dipengaruhi oleh total *neuron* yang dimiliki pada lapisan tersembunyi. Dalam arsitektur *deep learning*, total node *neuron* yang dimiliki terlalu sedikit atau terlalu banyak dapat menyebabkan model menjadi *underfitting* (Lecun et al., 2015). Untuk melakukan evaluasi pada klasifikasi kanker payudara menggunakan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur ResNet 50, DenseNet201, dan VGG-16.

2.6. Convolutional Neural Network (CNN)

Untuk memproses data dua dimensi, *Convolutional Neural Network* (CNN) adalah arsitektur pembelajaran mendalam dengan representasi *multi-layer*. CNN dapat melakukan proses pembelajaran abstrak pada fitur objek, khususnya data spasial, dan dapat generalisasi dengan lebih baik dibandingkan jaringan lain dengan lapisan tradisional yang sepenuhnya terhubung (Ghosh et al., 2019). Serta memiliki struktur *feed-forward* yang dalam dan dapat mengidentifikasi data dengan lebih efisien karena memiliki fitur representasi data berlaku untuk kedua transformasi *linier* dan fungsi *nonlinier* (Nugroho, 2020).

Model CNN dapat menjalankan proses pembelajaran pada berbagai jenis data karena memiliki banyak lapisan pemrosesan yang terbatas. Menggabungkan berbagai tingkat abstraksi. Lapisan inisiator akan menggunakan abstraksi tingkat rendah untuk mempelajari dan mengekstrak fitur tingkat tinggi, dan lapisan yang lebih dalam akan menggunakan abstraksi tingkat tinggi untuk mempelajari dan mengekstrak fitur tingkat rendah.



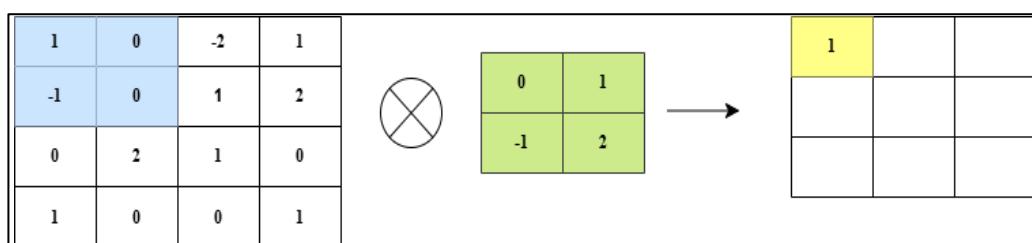
Gambar 6. Arsitektur Algoritma CNN (Alzubaidi et al., 2021).

CNN terdiri dari tiga lapisan, seperti yang ditunjukkan pada Gambar 6, yang merupakan struktur *neural network deep learning* lapisan masukan, lapisan keluaran, dan lapisan tersembunyi. Pada lapisan tersembunyi, terdapat empat lapisan utama, yaitu *convolutional*, ReLu, *pooling*, dan lapisan terhubung sepenuhnya.

2.6.1. Convolutional Layer

Lapisan *convolutional*, juga dikenal sebagai lapisan konvolusi, adalah bagian yang paling penting dari arsitektur CNN. Di dalam lapisan ini, kernel terdiri dari suatu kumpulan *filter* konvolusi yang berulang kali menerapkan fungsi pada keluaran lainnya. *Filter* ini memproses gambar masukan untuk menghasilkan peta *fitur* keluaran. Ini dilakukan dengan menggambarkan metrik N-dimensi pada gambar masukan.

Nilai diskrit dalam kotak atau angka adalah apa yang dikenal sebagai kernel. Setiap nilai yang ditampilkan di kotak hijau pada Gambar 6 dikenal sebagai bobot kernel. Pada awal proses pelatihan, terdapat nomor acak yang berfungsi sebagai bobot kernel. Selanjutnya, berat tersebut disesuaikan untuk setiap proses pelatihan guna mengidentifikasi *fitur* paling baik. Nilai yang dihasilkan ditunjukkan pada peta *fitur* keluaran dengan warna oranye.

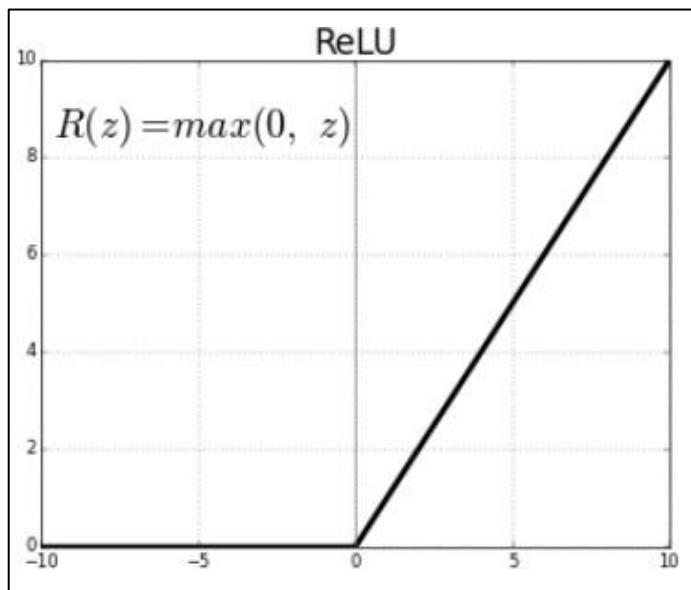


Gambar 7. Ilustrasi Operasi Konvolusi (Alzubaidi et al., 2021).

Menurut (Nugroho, 2020), dua parameter penting pada lapisan konvolusi, langkah satu menunjukkan ukuran langkah pada setiap lokasi vertikal dan horizontal yang diterapkan pada kernel, dan langkah dua menunjukkan ukuran langkah pada lapisan konvolusi dengan setengah tinggi dan lebar gambar. Sebaliknya, parameter *padding* sangat penting untuk mengidentifikasi data ukuran batas yang terkait dengan gambar masukan dan bagaimana ukuran peta fitur keluaran akan meningkat.

2.6.2. Rectified Linear Unit (ReLU)

Rectified linear unit (ReLU) merupakan salah satu fungsi aktivasi yang sering digunakan pada *Convolutional Neural Network* (CNN). Aktivasi ReLU dapat dilihat pada Gambar 8.

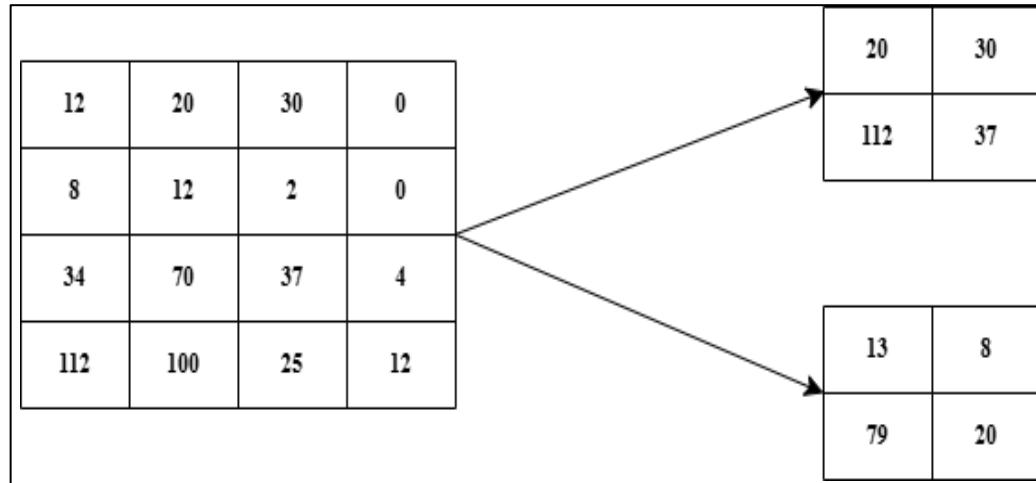


Gambar 8. *Rectified Linear Unit* (ReLU).

Pada Gambar 8 menunjukkan representasi aktivasi ReLU secara matematisnya adalah $f(x) = \max(0, x)$, dan ReLU dapat mengubah seluruh nilai input menjadi angka positif. Keuntungan utama dari fungsi ReLU adalah beban komputasi yang lebih rendah.

2.6.3. Polling Layer

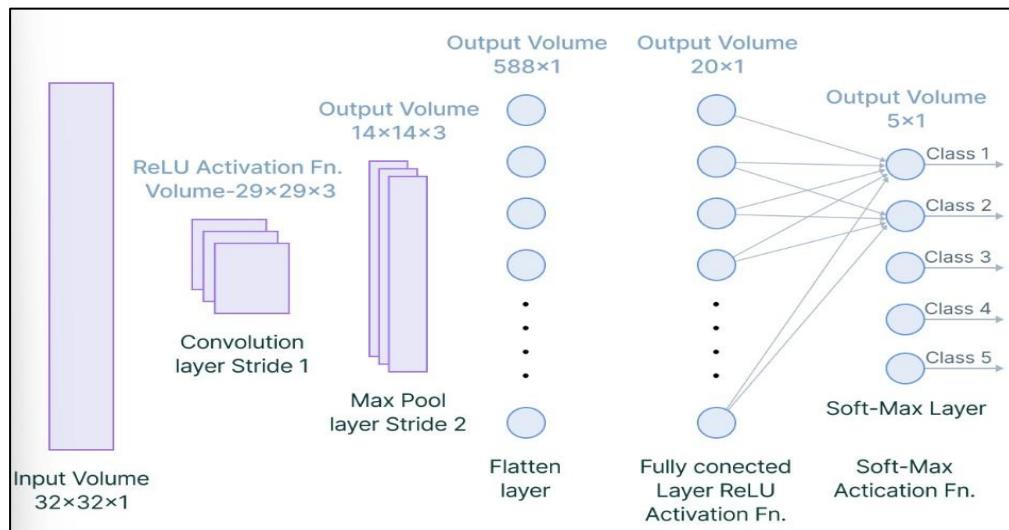
Untuk mengecilkan peta fitur yang berukuran besar menjadi lebih kecil adalah tujuan utama *layer pooling*. Lapisan penyautan menyimpan sebagian besar informasi atau fitur dalam setiap langkah penyautan. Sebagai contoh, lapisan *pooling* dapat menggunakan berbagai jenis *pooling*, seperti *tree pooling*, *gated pooling*, *average pooling*, *min pooling*, *max pooling*, *global average pooling*, dan *global max pooling*. Kinerja CNN secara keseluruhan dapat dipengaruhi oleh parameter lapisan *pooling* karena lapisan ini memungkinkan CNN untuk fokus pada ketersediaan fitur pada gambar masukan, melewaskan informasi penting yang dapat dilihat pada Gambar 9.



Gambar 9. *Pooling layer* (Alzubaidi et al., 2021).

2.6.4. Fully Connected Layer

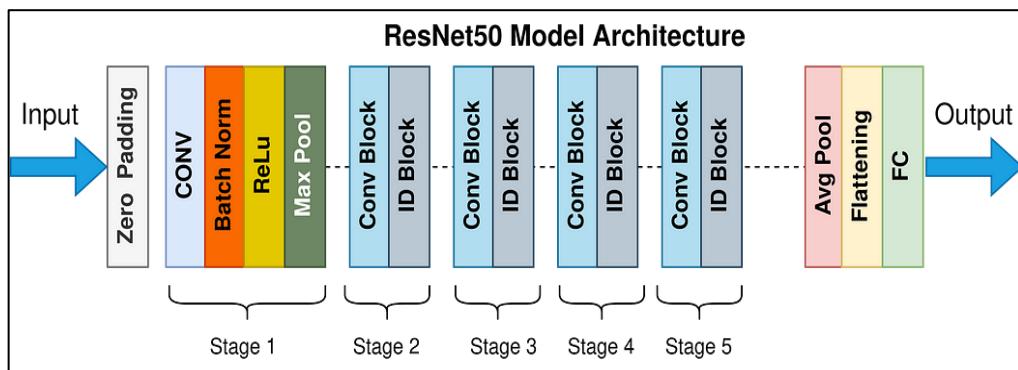
Untuk melakukan proses klasifikasi, *fully-connected layer* adalah langkah akhir dalam arsitektur CNN. Dalam lapisan ini, setiap *neuron* terhubung ke semuanya dari lapisan sebelumnya. Metode ini disebut pendekatan *Fully Connected* (FC). Masukan ke lapisan FC berasal dari lapisan konvolusi atau *pooling* terakhir, yang merupakan vektor yang dibuat dari peta fitur.



Gambar 10. *Fully Connected Layer* (www.v7labs.com).

2.7. Arsitektur ResNet50

ResNet50 adalah alat *deep convolutional neural network* yang dapat menangani masalah pelatihan *deep neural network* yang sering mengalami degradasi dan kehilangan *gradient* (K. He, X. Zhang, 2016). Arsitektur ResNet dikembangkan sebagai respon dari hasil eksperimen yang dilakukan dalam penelitian *deep learning* mengenai keandalan jaringan syaraf yang tidak selalu meningkat meskipun lapisannya ditambah. Ketika lapisan jaringan syaraf bertambah, muncul masalah yang dikenal dengan istilah degradasi performa, yaitu ketika jumlah lapisan bertambah, akurasi yang seharusnya meningkat justru menurun (K. He, X. Zhang, 2016), hal ini bukan disebabkan oleh *overfitting*, di mana model menjadi sangat spesifik terhadap data, tetapi lebih disebabkan oleh kesulitan dalam mempelajari model. Arsitektur ResNet50 dapat dilihat pada Gambar 11.

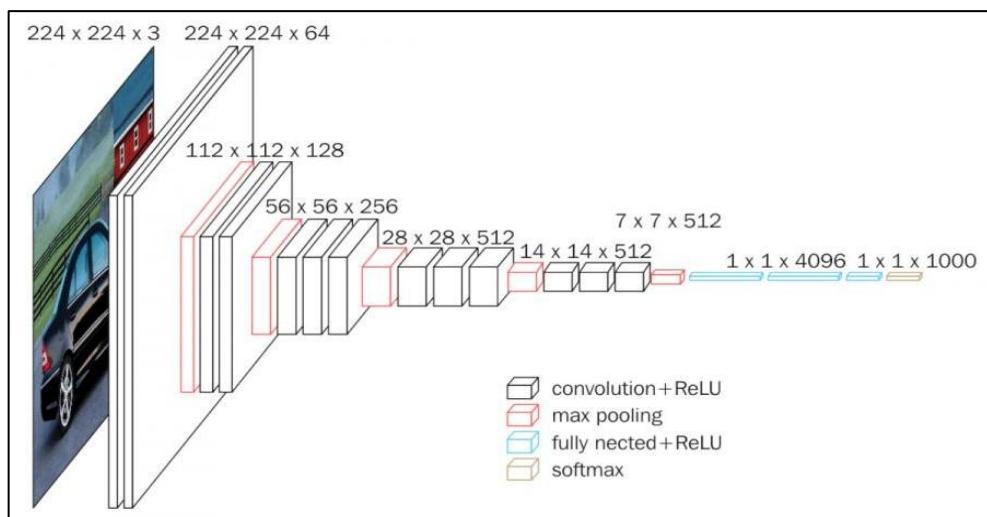


Gambar 11. Arsitektur ResNet50 (K. He, X. Zhang, 2016).

Pada Gambar 11 menunjukkan pendekatan kinerja arsitektur yang sangat efektif seperti ResNet50. Karena ada koneksi residual yang memungkinkan jaringan tetap stabil, bahkan pada kedalaman yang tetap, meningkat dari 20 ke 50 lapisan atau dari 50 ke 100 lapisan, meningkatkan lapisan tambahan tidak akan mempengaruhi kinerja. Koneksi residual ini memastikan bahwa kinerja jaringan tidak akan terpengaruh karena lapisan. Arsitektur ResNet yang paling terkenal adalah ResNet50, di mana angka 50 sesuai dengan jumlah lapisan dalam jaringan yang mencapai 50 lapisan. ResNet50 terdiri dari 16 blok sisa, yang masing-masing terdiri dari beberapa lapisan berbelit-belit dengan koneksi sisa. Arsitektur memungkinkan penyatuan, koneksi penuh, dan lapisan *softmax* untuk klasifikasi (K. He, X. Zhang, 2016).

2.8. Arsitektur Visual Geometry Group (VGG-16)

K.Simonyan dan A.Zisserman dari Universitas Oxford mengusulkan model jaringan saraf *convolutional neural network* VGG-16 pada tahun 2014. Model ini mencapai akurasi 92,7% pada tes top-5 di *ImageNet*, yang merupakan kumpulan data lebih dari 14 juta gambar dengan 1000 kelas. Salah satu jenis *Convolutional Neural Network* (CNN) terbaik saat ini adalah VGG16. Menggunakan arsitektur dengan filter *konvolusi* yang sangat kecil (3×3), pembuat model ini menilai jaringan dan meningkatkan kedalamannya. Setiap filter memiliki kemampuan untuk mengekstrak informasi yang berbeda tentang berbagai objek. VGG16 juga menggunakan ide lapisan yang lebih dalam. Lapisan yang lebih banyak berarti akurasi yang lebih tinggi (Setiawan, 2020). Arsitektur VGG16 dapat dilihat pada Gambar 12.

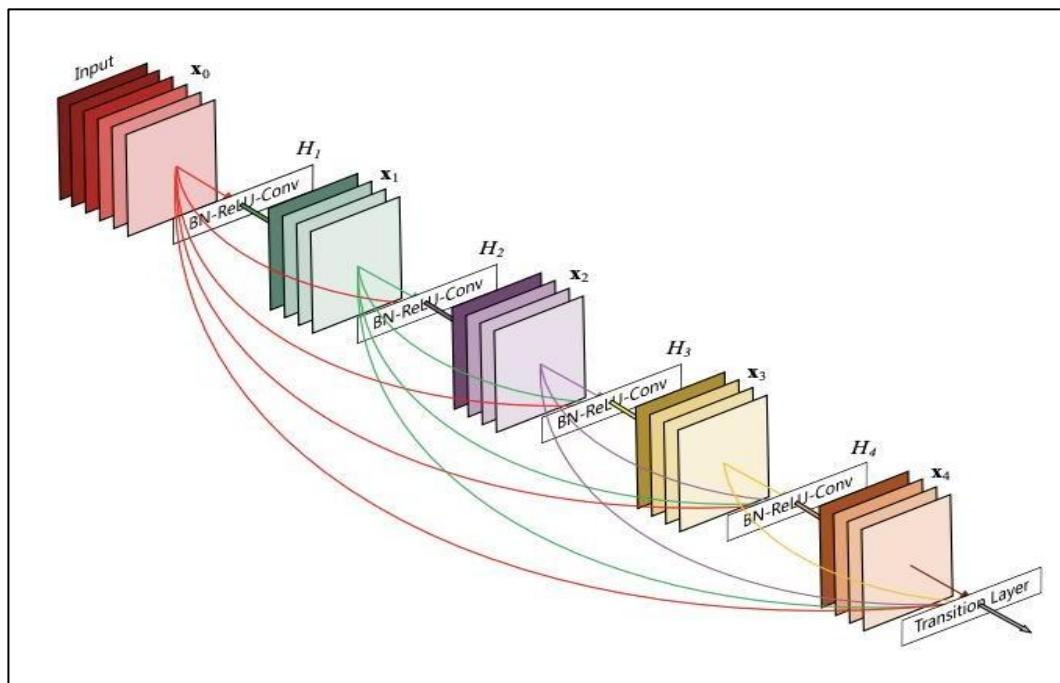


Gambar 12. Arsitektur VGG-16 (Almryad & Kutucu, 2020).

Pada Gambar 12 menunjukkan lapisan VGG16 yang memiliki 3 lapisan *fully-connected layer* dan 13 lapisan *convolutional*. Gambar *input defaultnya* adalah 224×224 pixel. Lapisan *convolutional* VGG-16 terdiri dari semua lapisan *convolutional* 3×3 dengan ukuran stride 1 dan bantalan yang sama, serta lapisan *pooling* 2×2 dengan ukuran stride 2. Lapisan *convolutional* pertama memiliki 64 filter, lapisan ke-2, 128 filter, 256 filter, dan lapisan ke-4 dan k Tumpukan lapisan *konvolusi* diikuti oleh tiga lapisan *Fully-Connected* (FC). Lapisan pertama memiliki 4096 saluran, dan lapisan ketiga melakukan klasifikasi ILSVRC 1000 arah, sehingga memiliki 1000 saluran, satu untuk setiap kelas.

2.9. Arsitektur DenseNet201

Dense Convolutional Network (DenseNet) adalah model arsitektur pada *Convolutional Neural Network* (CNN) guna menghubungkan satu lapisan ke lapisan berikutnya. Dalam jaringan konvolusi lapisan-L tradisional, setiap lapisan dan lapisan berikutnya memiliki koneksi L-1, tetapi pada jaringan ini ada koneksi langsung $L(L+1)/2$. DenseNet memiliki beberapa keunggulan yang menarik. Ini meningkatkan ekspansi fungsi, mengurangi masalah gradien, dan mendorong penggunaan kembali fungsi (Miranda et al., 2020). Arsitektur DenseNet201 dapat dilihat pada Gambar 13.



Gambar 13. Arsitektur DenseNet (amaarora, 2020).

Pada Gambar 13, batch normalisasi digunakan untuk setiap kombinasi lapisan, ReLU aktif, dan konvolusi dilakukan menggunakan filter 3x3. Setiap blok mengandung *input* dalam bentuk matriks *pixel* dari gambar, dan kemudian masuk ke tahap normalisasi batch untuk mengurangi *overfitting* dalam proses pembelajaran. Nilai variabel x diubah menjadi nilai 0 jika nilai variabel x negatif, dan sebaliknya jika nilai variabel x negatif.

2.10. Google Collaboratory

Colaboratory, atau "Colab", adalah suatu produk penelitian *Google* yang luar biasa dalam pembelajaran mesin, analisis data dan pendidikan, karena dapat memberikan kemampuan untuk membuat dan mengeksekusi sebuah kode *python* melalui browser (Soen et al., 2022). *Google Colab* telah menyediakan hampir semua perangkat lunak yang diperlukan untuk dapat diakses secara gratis secara online (Syarif, 2018). Untuk penelitian ini, pustaka seperti *Keras*, *TensorFlow*, *NumPy*, *Pandas*, dan pendukung lainnya diperlukan versi lengkap tersedia, seperti *TensorFlow* dan *Python*. Dari sisi perangkat keras, *Google Colab* menyediakan layanan berupa media penyimpan yang terintegrasi dengan *Google Drive* (Handayanto & Herlawati, 2020).

2.11. Image Augmentation

Augmentasi gambar adalah Salah satu metode penting dalam *deep learning*, yang meningkatkan keragaman dan ukuran kumpulan data pelatihan, menghasilkan peningkatan kinerja model. Banyak pendekatan baru telah diciptakan untuk menangani masalah tertentu dengan *overfitting* dan ketersediaan data yang terbatas. Meningkatkan akurasi pengenalan model, terutama dalam situasi dengan lingkungan yang kompleks dan sampel pelatihan terbatas adalah tujuan utama penggunaan augmentasi gambar. Ini sangat penting untuk klasifikasi kanker payudara karena kumpulan data mungkin tidak cukup besar untuk membangun model yang kuat (Huang et al., 2022).

2.12. Confusion Matrix

Confusion matrix adalah suatu metode yang banyak digunakan dalam pembelajaran mesin guna mengevaluasi atau memvisualisasikan bagaimana cara kinerja model dalam konteks klasifikasi (Caelen, 2017). Matriks yang digunakan mencakup *accuracy*, *Precision*, *Recall* dan *F1-Score*. Metode ini banyak digunakan untuk

klasifikasi pada arsitektur CNN. Tabel 2. menunjukkan *matrix confusion* untuk klasifikasi.

Tabel 2. *Confusion Matrix*

Gambar	Prediksi negatif	Prediksi positif
Negatif	TN	FP
Positif	FN	TP

Menurut (Kotu & Deshpande, 2014), terdapat 4 istilah yang biasa digunakan sebagai representasi hasil pada proses klasifikasi *confusion matrix*. Adapun keempat istilah tersebut yaitu.

1. *True Negative* (TN): Terjadi ketika kelas yang diprediksi adalah negatif, dan prediksi tersebut benar. Misalnya, sistem memprediksi kanker payudara jinak, dan benar bahwa kanker tersebut memang dalam kondisi jinak.
2. *False Negative* (FN): Terjadi ketika kelas yang diprediksi adalah negatif, dan prediksi tersebut salah. Misalnya, sistem memprediksi kanker payudara jinak, padahal sebenarnya kanker tersebut terkena *ganas*.
3. *False Positive* (FP): Terjadi ketika kelas yang diprediksi adalah positif, tetapi prediksi tersebut salah. Misalnya, sistem memprediksi kanker payudara terkena kanker ganas, tetapi sebenarnya kanker tersebut jinak.
4. *True Positive* (TP): Terjadi ketika kelas yang diprediksi adalah positif, dan prediksi tersebut benar. Misalnya, sistem deteksi penyakit kanker payudara terkena kanker ganas dan benar bahwa kanker tersebut memang terkena kanker ganas.

Adapun beberapa *performance matrix* yang umum dan sering digunakan,yaitu.

1. *Accuracy*

Accuracy menggambarkan kemampuan model untuk mengklasifikasikan sesuatu dengan benar. Akurasi dalam klasifikasi mengacu pada kemampuan model untuk memprediksi kelas dengan benar, baik positif maupun negatif. Ketika datatidak seimbang, model yang memprediksi kelas mayoritas (*positif*) mungkin memiliki nilai akurasi yang lebih tinggi daripada model yang mengidentifikasi kelas

minoritas (*negatif*). Model yang memprediksi kelas mayoritas (*positif*) mungkin kurang efektif dalam mendeteksi kelas minoritas (*negatif*). Untuk menghitung nilai *accuracy*, dapat menggunakan Persamaan 1.

2. *Precision*

Precision adalah metrik yang mengukur seberapa baik model memprediksi kelas positif dari semua prediksi *positif*. dari semua prediksi positif yang dibuat. Presisi dalam klasifikasi mengacu pada seberapa sering model secara akurat memprediksi kelas kelas *positif*, dibandingkan dengan semua prediksi *positif* yang diberikan oleh model. Untuk menghitung nilai *precision*, dapat menggunakan Persamaan 2.

$$precision = \frac{TP}{TP + FP} (2)$$

3. Recall

Statistik penilaian yang disebut *recall* mengindikasikan seberapa baik sebuah model mengenali kelas *positif*. Jumlah prediksi *positif* yang akurat dibagi dengan seluruh jumlah data yang benar-benar positif adalah *recall*. Untuk menghitung *recall*, dapat menggunakan Persamaan 3.

4. *F1-Score*

F1-Score adalah *matrix* evaluasi yang menggambarkan keseimbangan antara presisi dan *recall*. Nilai *F1-Score* akan memberikan gambaran sejauh mana model mampu mengintegrasikan presisi dan *recall*. Untuk menghitung *F1-Score* dapat menggunakan Persamaan 4.

$$F1 - Score = 2 \times \frac{recall \times precision}{recall + precision} \quad (4)$$

3.2. Alat dan Bahan

Adapun alat dan bahan yang digunakan dalam penelitian adalah *Hardware* dan *Software* sebagai berikut.

3.2.1. *Hardware*

Hardware yang digunakan dalam penelitian ini adalah laptop Acer Aspire A512-54 dengan spesifikasi sebagai berikut.

1. *Processor: Intel Core i5-1135G7*
2. *Installed: RAM 8 GB*
3. *System Type: 64-bit operating system, x64-based processor*

3.2.2. *Software*

Software yang digunakan dalam penelitian ini antara lain sebagai berikut.

1. Sistem operasi *Windows 11*
2. Tools: *Google Colab* untuk menjalankan kode secara *cloud*, *Python* digunakan sebagai bahasa pemrograman utama dan *Google Drive* sebagai penyimpanan dataset.

3.2.3. *Library*

Library yang digunakan dalam penelitian ini antara lain sebagai berikut.

1. *NumPy 2.0.2.*

NumPy adalah salah satu *library* paling populer untuk komputasi ilmiah. *Library numpy* menyediakan operasi matematika pada array dan matriks tersedia pula fungsi di *library Open cv* (Sundaram et al., 2023).

2. *Tensorflow 2.18.0.*

TensorFlow dalam *Python* menyediakan dukungan untuk berbagai algoritma pembelajaran mesin (*Machine Learning*) dan pembelajaran mendalam (*Deep Learning*). Program ini mencakup berbagai *tools*, termasuk untuk mengevaluasi dan menerapkan model, serta *tools* untuk membuat dan melatih jaringan saraf (Sundaram et al., 2023).

3. *Keras 3.8.0.*

Keras adalah sebuah pustaka jaringan saraf tingkat tinggi berbasis *Python* yang digunakan di platform *TensorFlow*, *Theano*, dan CNTK untuk membangun jaringan saraf yang kuat. Keras memiliki antarmuka yang mudah digunakan, yang menjadikan proses pembuatan model pembelajaran mendalam lebih sederhana (Sundaram et al., 2023).

4. *Matplotlib 3.10.0.*

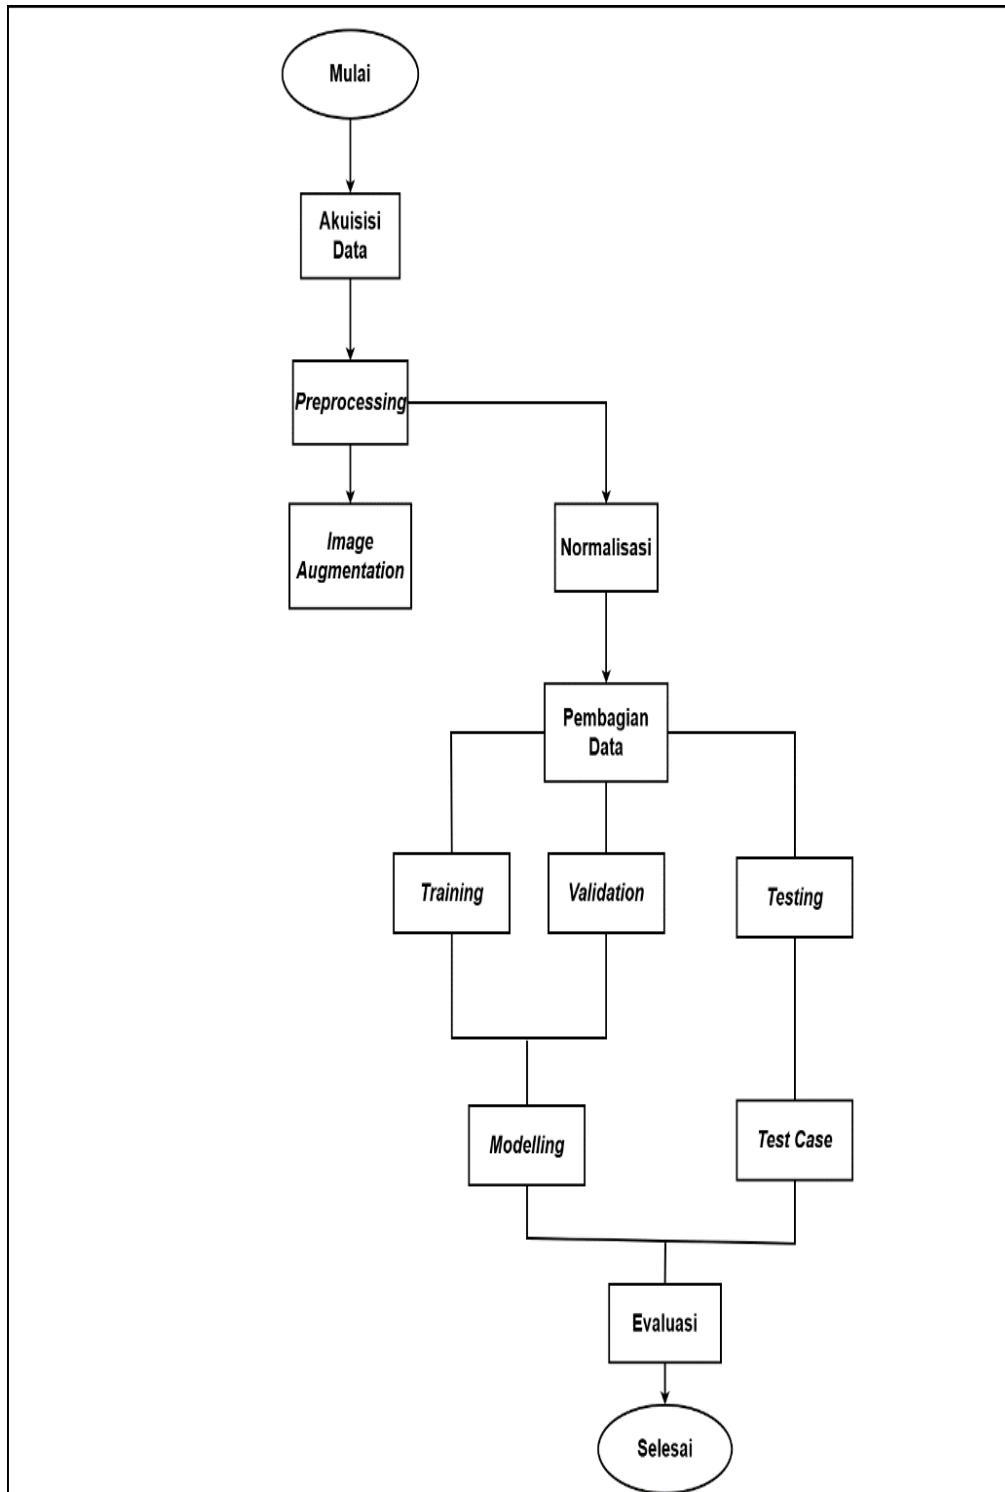
Perpustakaan *Matplotlib* dalam *Python* digunakan untuk membuat visualisasi statis, animasi, dan visualisasi interaktif menggunakan *Python*. Perpustakaan ini menyediakan berbagai jenis grafik yang dapat disesuaikan dan tersedia untuk banyak format (Sundaram et al., 2023).

5. *Scikit-Learn 1.6.0.*

Scikit-learn adalah library dalam *Python* yang mendukung berbagai algoritma pembelajaran mesin seperti klasifikasi, regresi, dan klastering. Selain itu, *library* ini juga menyediakan alat untuk dapat memilih dan mengevaluasi suatu model (Sundaram et al., 2023).

3.3. Tahapan Penelitian

Dalam penelitian ini ada beberapa tahapan yang dilakukan digambarkan pada Gambar 14. sebagai berikut.

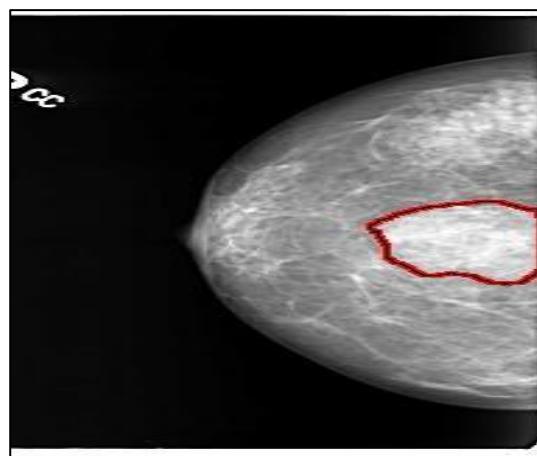


Gambar 14. Alur Kerja Penelitian.

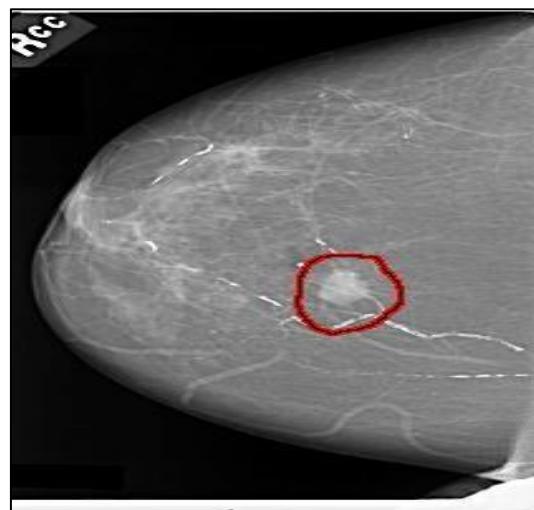
3.3.1. Akuisisi Data

Data yang akan digunakan dalam penelitian ini adalah diambil dari website <https://www.kaggle.com/datasets/cheddad/miniddsm/data>. Gambar mammography Payudara berasal dari sumber data publik. Data awalnya dikumpulkan pada tahun 2020. Gambar kanker payudara menggunakan format PNG yang terdiri dari 3 kelas yaitu Normal, Jinak dan Ganas. Gambar kebenaran dasar disertakan dengan gambar aslinya. Pengelompokan gambar dapat dilihat pada Gambar 15,16 dan 17.

1. Abnormal

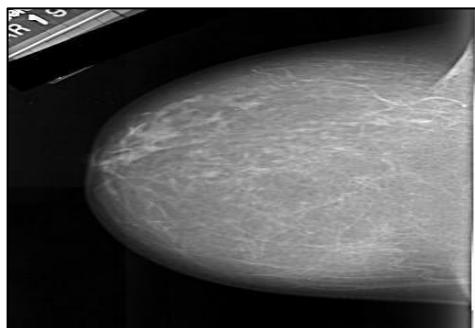


Gambar 15. Payudara Jinak (www.kaggle.com).



Gambar 16. Payudara Ganas (www.kaggle.com).

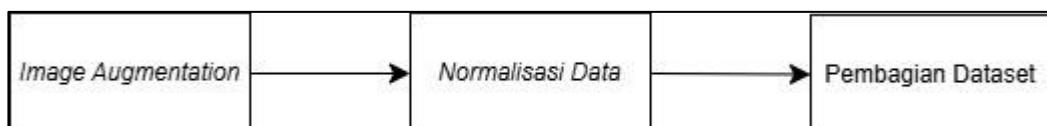
2. Normal



Gambar 17. Payudara Normal (www.kaggle.com).

3.3.2. *Pre-Processing*

Tahap *pre-processing* merupakan sebuah tahap persiapan data untuk pelatihan model dengan melakukan beberapa penyesuaian dan normalisasi terhadap data. Proses data *pre-processing* yang dilakukan pada penelitian ini antara lain normalisasi data dan pembagian data menjadi data *training*, *validation* dan *testing*. Pada penelitian ini alur *preprocessing* dapat dilihat dalam Gambar 18 berikut.



Gambar 18. Alur *Preprocessing* Data.

1. *Image Augmentation*

Image augmentation adalah teknik *deep learning* yang meningkatkan volume dan keragaman data pelatihan dengan melakukan beberapa perubahan pada gambar asli. Teknik *image augmentation* yang digunakan dalam penelitian ini bertujuan untuk meningkatkan variasi dataset kanker payudara untuk meningkatkan kemampuan generalisasi model CNN, termasuk mengidentifikasi pola dari berbagai kelas penyakit kanker payudara seperti Normal dan Abnormal serta Jinak dan Ganas. Transformasi yang digunakan adalah *Flipping* dan *Rotation*. Strategi ini membantu model dalam mengenali pola yang lebih rumit dan bervariasi, serta mencegah *overfitting*, yang terjadi ketika model hanya mengingat data pelatihan dan memiliki

kemampuan generalisasi yang signifikan. Dengan demikian, augmentasi gambar membantu meningkatkan akurasi dan kinerja model CNN.

Tabel 4. Skenario Balance 1

<i>Imbalanced</i>		<i>Balanced</i>	
Abnormal	6956	Abnormal	6956
Normal	2728	Normal	6956
Total	9684	Total	13912

Tabel 5. Skenario Balance 2

<i>Imbalanced</i>		<i>Balanced</i>	
Ganas	3596	Ganas	3596
Jinak	3360	Jinak	3596
Total	6959	Total	7192

Pada Tabel 4 dalam skenario data *balance* menggunakan Teknik *over sampling* untuk mengambil sejumlah data terbanyak pada data kanker payudara Normal dan Abnormal dengan masing-masing kelas sejumlah 6956 data dengan total 13912 data. Sedangkan pada Tabel 5 skenario *imbalanced* data mengikuti jumlah kanker payudara jinak sebanyak 3360 kemudian data kanker ganas sebanyak 3596 dengan total 6956 data.

2. Normalisasi Data

Tahap selanjutnya adalah normalisasi data. Tahap ini merupakan langkah penting dalam *preprocessing* data karena bertujuan untuk memastikan model klasifikasi dapat menerima data dalam skala yang konsisten. Normalisasi juga membantu mempercepat konvergensi model selama pelatihan dengan menyelaraskan skala data yang masuk ke dalam jaringan. Normalisasi umumnya dilakukan dengan mereskalakan nilai pixel dari gambar sehingga berada dalam rentang 0 hingga 1. Hal ini dilakukan dengan membagi setiap nilai piksel dengan 255, karena nilai piksel asli berada dalam rentang 0 hingga 255.

$$\text{Nilai Normalisasi} = \frac{\text{Nilai Pixel asli}}{255}$$

3. Pembagian Dataset

Pada tahap ini pembagian data dibagi menjadi tiga subset yaitu data *training*, *validation*, dan *testing*. Tahap pembagian data ini dilakukan untuk memastikan bahwa model dapat di *training*, *validation* dan *testing* dengan data yang berbeda, sehingga kinerja model dapat dievaluasi dengan akurat dan menghindari *overfitting*. Data *training* digunakan untuk melatih model dalam mengenali pola-pola yang ada. Data *validation* digunakan selama pelatihan untuk mengevaluasi kinerja model pada data yang tidak terlihat oleh model selama pelatihan, data ini akan dimanfaatkan untuk mengoptimalkan model pada tahap *hyperparameter tuning*. Data *testing* merupakan data yang tidak pernah dilihat oleh model dan digunakan untuk memberikan estimasi akurasi model. Jumlah data yang digunakan pada skema 1 berjumlah 13912 dan skema 2 berjumlah 7192. Yang dapat dilihat pada Tabel 6 dan 7.

Tabel 6. Pembagian Data (80%: 10%: 10%) Skema 1

Pembagian Data	Rasio	Jumlah Data
<i>Training</i>	80%	11130
<i>Validation</i>	10%	1391
<i>Testing</i>	10%	1391
Total	100%	13912

Tabel 7. Pembagian Data (70%: 15%: 15%) Skema 1

Pembagian Data	Rasio	Jumlah Data
<i>Training</i>	70%	9738
<i>Validation</i>	15%	2087
<i>Testing</i>	15%	2087
Total	100%	13912

Pada Tabel 6 dijelaskan pembagian data pada skema 1 dengan pembagian data *training* 80% dengan jumlah data 11130, data *validation* 10% dengan jumlah data 1391, dan *testing* 10% dengan jumlah data 1391. Dan pada Tabel 7 pembagian data *training* 70% dengan jumlah data 9738, data *validation* 15% dengan jumlah data 2087, dan data *testing* 15% dengan jumlah data 2087.

Tabel 8. Pembagian Data (80%: 10%: 10%) Skema 2

Pembagian Data	Rasio	Jumlah Data
Training	80%	5753
Validation	10%	719
Testing	10%	719
Total	100%	7192

Tabel 9. Pembagian Data (70%: 15%: 15%) Skema 2

Pembagian Data	Rasio	Jumlah Data
Training	70%	5034
Validation	15%	1078
Testing	15%	1078
Total	100%	7192

Pada Tabel 8 dijelaskan pembagian data pada skema 2 dengan pembagian data *training* 80% dengan jumlah data 5753, data *validation* 10% dengan jumlah data 719, dan *testing* 10% dengan jumlah data 719. Dan pada Tabel 9 pembagian data *training* 70% dengan jumlah data 5034, data *validation* 15% dengan jumlah data 1078, dan data *testing* 15% dengan jumlah data 1078.

3.4. Modelling

Pada *Convolutional Neural Network* arsitektur yang digunakan dalam penelitian ini adalah arsitektur Resnet50, VGG-16 dan DenseNet201. Pemilihan ketiga arsitektur ini didasarkan pada penelitian (Agarwal & Singh, 2022) dimana model yang diujikan menghasilkan tingkat akurasi tertinggi adalah model dengan arsitektur

Resnet50, VGG-16 dan DenseNet. Pada proses klasifikasi pada arsitektur VGG-16 dengan pemrosesan data, di mana pada gambar kanker payudara dapat dimuat dan *resize* untuk mengidentifikasi secara relevan (Simonyan et al., 2014). DenseNet201 membantu menyelesaikan masalah *vanishing-gradients* dipenggunaan ulang dan penyebaran fitur yang hilang (Agarwal & Singh, 2022). ResNet50 memiliki fitur koneksi lompatan, dimana input ke suatu lapisan dapat segera diteruskan ke beberapa lapisan lain untuk meningkatkan efisiensi jaringan saraf dibandingkan dengan arsitektur lain (Agarwal & Singh, 2022). Selain itu, fitur ini juga membantu mengatasi masalah *gradien* yang hilang dengan memanfaatkan pemetaan identitas (Agarwal & Singh, 2022). Pada tahapan ini sebuah algoritma belajar untuk mengenai pola gambar dari dataset dengan melakukan *training, validation dan testing*. Model akan dilatih dengan 30 *epoch* namun akan menggunakan *early stopping* sehingga dapat dilakukan penghentian lebih awal karena adanya *validation-loss*.

3.5. Evaluasi

Tujuan dari evaluasi ini adalah untuk meningkatkan performa arsitektur CNN dan dalam mengkategorikan penyakit kanker payudara ke dalam dua kategori yaitu, Normal dan Abnormal serta Jinak dan Ganas. Pengujian dilakukan pada data uji untuk menilai sejauh mana model dapat mengidentifikasi satu jenis penyakit kanker payudara secara akurat. Untuk mengevaluasi performa model, digunakan beberapa metrik, antara lain *accuracy, precision, recall*, dan F1-score. Evaluasi performa model juga dibantu dengan *confusion matrix* untuk menggambarkan hasil prediksi dan kesalahan klasifikasi pada setiap kelas. Hal ini membantu melihat seberapa baik model dapat mengenali pola penyakit pada kanker payudara.

IV. KESIMPULAN DAN SARAN

5.1. Kesimpulan

1. Penelitian ini membuktikan bahwa pendekatan klasifikasi dua tahap memberikan hasil yang lebih optimal dibandingkan klasifikasi langsung multi-kelas. Tahap pertama memfokuskan model pada deteksi awal, yaitu membedakan antara citra Normal dan Abnormal, sedangkan tahap kedua lebih spesifik dalam membedakan jenis kelainan, yaitu Jinak dan Ganas. Pendekatan bertingkat ini memungkinkan model untuk lebih fokus mengenali pola visual yang berbeda pada setiap tahap, sehingga mampu meningkatkan akurasi deteksi dan mengurangi kesalahan klasifikasi medis.
2. Hasil eksperimen menunjukkan bahwa arsitektur DenseNet201 dapat memberikan kinerja terbaik pada skema 1 (Normal dan Abnormal) dengan pembagian data 80:10:10 dan akurasi mencapai 92%. Sedangkan pada skema 2 (Jinak dan Ganas) dengan rasio data 70:15:15, sedangkan arsitektur ResNet50 menunjukkan performa tertinggi dengan akurasi 82%, membuktikan bahwa arsitektur ini efektif dalam menangani perbedaan visual yang lebih kompleks.
3. Selain akurasi, penelitian ini juga menekankan pentingnya menggunakan metrik evaluasi lainnya seperti Precision, Recall, dan F1-Score untuk memberikan penilaian menyeluruh terhadap performa model dalam konteks klasifikasi kanker payudara, terutama ketika data tidak seimbang. Temuan ini diharapkan dapat menjadi dasar pengembangan sistem bantu diagnosis yang lebih andal, akurat dalam bidang kesehatan.

5.2. Saran

1. Disarankan untuk mengintegrasikan teknik *ensemble learning* dengan menggabungkan beberapa arsitektur CNN yang berbeda untuk meningkatkan performa klasifikasi serta mengurangi risiko kesalahan prediksi akibat keterbatasan model tunggal.
2. Perlu dilakukan studi lebih mendalam terkait pengaruh preprocessing citra, seperti penghapusan noise dan peningkatan kontras, terhadap performa model agar data input yang diberikan ke CNN lebih optimal dan relevan untuk klasifikasi.
3. Menambah variasi data dengan augmentasi dan menggunakan dataset dari sumber berbeda dapat meningkatkan kemampuan generalisasi model.

DAFTAR PUSTAKA

- Almryad, A. S., & Kutucu, H. (2020). *Automatic identification for field butterflies by convolutional neural networks*. *Engineering Science and Technology, an International Journal*, 23(1), 189–195. <https://doi.org/10.1016/j.jestch.2020.01.006>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*. *Journal of Big Data*, 8(1), 53. <https://doi.org/10.1186/s40537-021-00444-8>
- Arafah, A. B. R., & Notobroto, H. B. (2018). faktor yang berhubungan dengan perilaku ibu rumah tangga melakukan pemeriksaan payudara sendiri (sadari). *The Indonesian Journal of Public Health*, 12(2), 143. <https://doi.org/10.20473/ijph.v12i2.2017.143-153>
- Atthalla, I. N., Jovandy, A., & Habibie, H. (2018). Klasifikasi Penyakit Kanker Payudara Menggunakan Metode K Nearest Neighbor. *Prosiding Annual Research Seminar*, 4(1), 148-151.
- Busaleh, M., Hussain, M., Aboalsamh, H. A., & Fazal-E-amin. (2021). Breast mass classification using diverse contextual information and convolutional neural network. *Biosensors*, 11(11), 419. <https://doi.org/10.3390/bios11110419>
- Caelen, O. (2017). A Bayesian interpretation of the confusion matrix. *Annals of Mathematics and Artificial Intelligence*, 81(3–4), 429-450. <https://doi.org/10.1007/s10472-017-9564-8>
- Cahya, F. N., Hardi, N., Riana, D., & Hadiyanti, S. (2021). Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN). *SISTEMASI*, 10(3), 618. <https://doi.org/10.32520/stmsi.v10i3.1248>
- Caron, M., Bojanowski, P., Joulin, A., & Douze, M. (2018). Deep clustering for unsupervised learning of visual features. In *Lecture Notes in Computer Science* (Vol. 11218 LNCS, pp. 139–156). Springer Verlag. https://doi.org/10.1007/978-3-030-01264-9_9
- Chakravarthy, S., Bharanidharan, N., Khan, S. B., Kumar, V. V., Mahesh, T. R., Almusharraf, A., & Albalawi, E. (2024). Multi-class Breast Cancer Classification Using CNN Features Hybridization. *International Journal of*

- Computational Intelligence Systems*, 17(1), 191.
<https://doi.org/10.1007/s44196-024-00593-7>
- Cruz-Roa, A., Basavanhally, A., González, F., Gilmore, H., Feldman, M., Ganesan, S., ... Madabhushi, A. (2014). Automatic detection of invasive ductal carcinoma in whole slide images with convolutional neural networks. In *Medical Imaging 2014: Digital Pathology* (Vol. 9041, p. 904103). SPIE. <https://doi.org/10.1117/12.2043872>
- Diwakaran, M., & Surendran, D. (2023). Breast Cancer Prognosis Based on Transfer Learning Techniques in Deep Neural Networks. *Information Technology and Control*, 52(2), 381–396. <https://doi.org/10.5755/j01.itc.52.2.33208>
- Dyanti, G. A. R., & Suariyani, N. L. P. (2016). Faktor-faktor keterlambatan penderita kanker payudara dalam melakukan pemeriksaan awal ke pelayanan kesehatan. *Jurnal Kesehatan Masyarakat*, 11(2), 276. <https://doi.org/10.15294/kemas.v11i2.3742>
- Fauzan Novriandy, M., Rahmat, B., & Junaidi, A. (2024). Klasifikasi Citra Pada Penyakit Kanker Mulut Menggunakan Arsitektur DenseNet201 Menggunakan Optimasi Adam Dan Sgd. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(4), 6132–6140. <https://doi.org/10.36040/jati.v8i4.10077>
- François-Lavet, V., Henderson, P., Islam, R., Bellemare, M. G., & Pineau, J. (2018). An introduction to deep reinforcement learning. *Foundations and Trends in Machine Learning*, 11(3–4), 219–354. <https://doi.org/10.1561/2200000071>
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2019). *Fundamental concepts of convolutional neural network*. In *Intelligent Systems Reference Library* (Vol. 172, pp. 519–567). Springer. https://doi.org/10.1007/978-3-030-32644-9_36
- Gupta, P. (2023). Leveraging Machine Learning and Artificial Intelligence for Fraud Prevention. *International Journal of Computer Science and Engineering*, 10(5), 47-52. <https://doi.org/10.14445/23488387/ijcse-v10i5p107>
- Handayanto, R. T., & Herlawati, H. (2020). Prediksi Kelas Jamak dengan Deep Learning Berbasis Graphics Processing Units. *Jurnal Kajian Ilmiah*, 20(1), 67–76. <https://doi.org/10.31599/jki.v20i1.71>
- Hossain, A. B. M. A., Nisha, J. K., & Johora, F. (2023). Breast Cancer Classification from Ultrasound Images using VGG16 Model based Transfer Learning. *International Journal of Image, Graphics and Signal Processing*, 15(1), 12–22. <https://doi.org/10.5815/ijigsp.2023.01.02>
- Huang, Y., Li, R., Wei, X., Wang, Z., Ge, T., & Qiao, X. (2022). Evaluating Data Augmentation Effects on the Recognition of Sugarcane Leaf Spot. *Agriculture (Switzerland)*, 12(12), 1997. <https://doi.org/10.3390/agriculture12121997>
- Idawati, I., Rini, D. P., Primanita, A., & Saputra, T. (2024). Klasifikasi Kanker

- Payudara Menggunakan Metode *Convolutional Neural Network* (CNN) dengan Arsitektur VGG-16. *Jurnal Sistem Komputer Dan Informatika (JSON)*, 5(3), 529. <https://doi.org/10.30865/json.v5i3.7553>
- K. He, X. Zhang, S. R. and J. S. (2016). “Deep Residual Learning for Image Recognition,” 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, 2016, pp. 770-778. doi: 10.1109/CVPR.2016.90.
- Khan, M. M., Tazin, T., Zunaid Hussain, M., Mostakim, M., Rehman, T., Singh, S., Gupta, V., & Alomeir, O. (2022). Breast Tumor Detection Using Robust and Efficient Machine Learning and Convolutional Neural Network Approaches. *Computational Intelligence and Neuroscience*, 2022, 11. <https://doi.org/10.1155/2022/6333573>
- Kotu, V., & Deshpande, B. (2014). *Predictive Analytics and Data Mining: Concepts and Practice with RapidMiner. Predictive Analytics and Data Mining: Concepts and Practice with RapidMiner* (pp. 1–425). Elsevier Inc. <https://doi.org/10.1016/C2014-0-00329-2>
- Kumar, T. S., Sridhar, G., Manju, D., Subhash, P., & Nagaraju, G. (2023). Breast Cancer Classification and Predicting Class Labels Using ResNet50. *Journal of Electrical Systems*, 19(4), 270–278. <https://doi.org/10.52783/jes.638>
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Liu, J., Lei, J., Ou, Y., Zhao, Y., Tuo, X., Zhang, B., & Shen, M. (2023). Mammography diagnosis of breast cancer screening through machine learning: a systematic review and meta-analysis. *Clinical and Experimental Medicine*, 23(6), 2341-2356. <https://doi.org/10.1007/s10238-022-00895-0>
- Liu, K., Kang, G., Zhang, N., & Hou, B. (2018). Breast Cancer Classification Based on Fully-Connected Layer First Convolutional Neural Networks. *IEEE Access*, 6, 23722-23732. <https://doi.org/10.1109/ACCESS.2018.2817593>
- Mahesh, B. (2020). Machine Learning Algorithms - A Review. *International Journal of Science and Research (IJSR)*, 9(1), 381-386. <https://doi.org/10.21275/art20203995>
- Maulana, R., Dwi Zahra Putri, R., Ade Amelia, T., Syahputra, H., & Ramadhani, F. (2024). Identifikasi Jenis Rempah-Rempah Indonesia Dengan Convolutional Neural Network (Cnn) Menggunakan Arsitektur Vgg16. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(4), 6034–6039. <https://doi.org/10.36040/jati.v8i4.10138>
- Miranda, N. D., Novamizanti, L., & Rizal, S. (2020). CONVOLUTIONAL NEURAL NETWORK PADA KLASIFIKASI SIDIK JARI MENGGUNAKAN RESNET-50. *Jurnal Teknik Informatika (Jutif)*, 1(2), 61-68. <https://doi.org/10.20884/1.jutif.2020.1.2.18>
- Nima, R., & Shila, F. (2020). Crack classification in rotor-bearing system by means of wavelet transform and deep learning methods: an experimental

- investigation. *Journal of Mechanical Engineering, Automation and Control Systems*, 1(2), 102-113. <https://doi.org/10.21595/jmeacs.2020.21799>
- Nugroho, P. A., Fenriana, I., & Arijanto, R. (2020). Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia. *Algor*, 2(1), 12–21.
- Pacilè, S., Lopez, J., Chone, P., Bertinotti, T., Grouin, J. M., & Fillard, P. (2020). Improving breast cancer detection accuracy of mammography with the concurrent use of an artificial intelligence tool. *Radiology: Artificial Intelligence*, 2(6), 1-9. <https://doi.org/10.1148/ryai.2020190208>
- Parisi, L. (2018). AI (ARTIFICIAL INTELLIGENCE). In *Posthuman Glossary* (pp. 21–23). Bloomsbury Publishing Plc. <https://doi.org/10.1093/oxfordhb/9780195309799.003.0007>
- Pramestya, R. H. (2018). Deteksi dan Klasifikasi Kerusakan Jalan Aspal Menggunakan Metode YOLO Berbasis Citra Digital. *Institut Teknologi Sepuluh Nopember*, 91. Retrieved from http://repository.its.ac.id/59044/1/06111650010019-Master_Thesis.pdf
- Rebala, G., Ravi, A., & Churiwala, S. (2019). Machine Learning Definition and Basics. In *An Introduction to Machine Learning* (pp. 1–17). Springer International Publishing. https://doi.org/10.1007/978-3-030-15729-6_1
- Savitri, A., Alina, L., & Utami, E. D. R. (2015). Kupas Tuntas Kanker Payudara, Leher Rahim dan Rahim. In *Yogyakarta: Pustaka Baru PressSusilawati, D.(2013). Hubungan Dukungan Keluarga dengan Tingkat Kecemasan Penderita Kanker Serviks Paliatif di RSUP dr. Sardjito Yogyakarta. Jurnal Keperawatan Diponegoro* (Vol. 4, Issue 2).
- Setiawan, W. (2020). PERBANDINGAN ARSITEKTUR CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI FUNDUS. *Jurnal Simantec*, 7(2), 48-53. <https://doi.org/10.21107/simantec.v7i2.6551>
- Soen, G. I. E., Marlina, M., & Renny, R. (2022). Implementasi Cloud Computing dengan Google Colaboratory pada Aplikasi Pengolah Data Zoom Participants. *JITU : Journal Informatic Technology And Communication*, 6(1), 24-30. <https://doi.org/10.36596/jitu.v6i1.781>
- Spanhol, F. A., Oliveira, L. S., Petitjean, C., & Heutte, L. (2016). A Dataset for Breast Cancer Histopathological Image Classification. *IEEE Transactions on Biomedical Engineering*, 63(7), 1455-1462. <https://doi.org/10.1109/TBME.2015.2496264>
- Sundaram, J., Gowri, K., Devaraju, S., Gokuldev, S., Jayaprakash, S., Anandaram, H., Manivasagan, C., & Thenmozhi, M. (2023). *An exploration of python libraries in machine learning models for data science* (pp. 1-31). <https://doi.org/10.4018/978-1-6684-8696-2.ch001>
- Susilowati, E., Hapsari, A. T., Efendi, M., & Edi, P. (2019). Diagnosa Penyakit Kanker Payudara Menggunakan Metode K - Means Clustering. *Jurnal Sistem Informasi, Teknologi Informatika Dan Komputer*, 10(1), 27–32.

- Ulagamuthalvi, V., Kulanthaivel, G., Balasundaram, A., & Sivaraman, A. K. (2022). Breast Mammogram Analysis and Classification Using Deep Convolution Neural Network. *Computer Systems Science and Engineering*, 43(1), 275–289. <https://doi.org/10.32604/csse.2022.023737>
- Wiliyanarti, P. F. (2021). Kualitas Hidup Pasien Kanker Payudara “Pendekatan Health Belief Model “ - Pipit Festi Wiliyanarti - Google Buku. In *UM Surabaya*.