



**IMPLEMENTASI TRANSFER LEARNING DAN CONVOLUTIONAL
NEURAL NETWORK (CNN) DALAM KLASIFIKASI KUALITAS
HASIL CETAK PRINTER LASER PADA PT. XYZ**

SKRIPSI

Oleh:

RANGGA BARANTA

20211000015

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI**

**UNIVERSITAS BUDDHI DHARMA
TANGERANG**

2025



**IMPLEMENTASI TRANSFER LEARNING DAN CONVOLUTIONAL
NEURAL NETWORK (CNN) DALAM KLASIFIKASI KUALITAS
HASIL CETAK PRINTER LASER PADA PT. XYZ**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana pada
Program Studi Teknik Informatika Fakultas Sains dan Teknologi**

**Universitas Buddhi Dharma
Jenjang Pendidikan Strata 1**

Oleh:

RANGGA BARANTA

20211000015

FAKULTAS SAINS DAN TEKNOLOGI

**UNIVERSITAS BUDDHI DHARMA
TANGERANG**

2025

LEMBAR PENYATAAN KEASLIAN SKRIPSI

Yang bertanda tangan dibawah ini.

NIM : 20211000015
Nama : Rangga Baranta
Jenjang Studi : Strata I
Program Studi : Teknik Informatika
Peminatan : Data Science

Dengan ini saya menyatakan bahwa:

1. Skripsi ini adalah asli dan belum pernah diajukan untuk mendapat gelar akademik Sarjana atau kelengkapan studi, baik di Universitas Buddhi Dharma maupun di Perguruan Tinggi lainnya.
2. Skripsi ini saya buat sendiri tanpa bantuan dari pihak lain, kecuali arahan dosen pembimbing.
3. Dalam Skripsi ini tidak terdapat karya atau pendapat yang telah ditulis atau dipublikasikan orang lain, kecuali secara tertulis dengan jelas dan dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan dicantumkan daftar pustaka.
4. Dalam Skripsi ini tidak terdapat pemalsuan (kebohongan), seperti buku, artikel, jurnal, data sekunder, pengolahan data, dan pemalsuan tanda tangan dosen atau Ketua Program Studi Universitas Buddhi Dharma yang dibuktikan dengan keasliannya..
5. Lembar pernyataan ini saya buat dengan sesungguhnya, tanpa paksaan dan apabila dikemudian hari atau pada waktu lainnya terdapat penyimpangan dan ketidak benaran dalam pernyataan ini, saya bersedia menerima sanksi akademik berupa pencabutan gelar akademik yang telah saya peroleh karena Skripsi ini serta sanksi lainnya sesuai dengan peraturan dan norma yang berlaku.

Tangerang, 5 Agustus 2025



Rangga Baranta

20211000015

LEMBAR PERSETUJUAN PUBLIKASI KARYA ILMIAH

Yang bertanda tangan dibawah ini.

NIM : 20211000015
Nama : Rangga Baranta
Jenjang Studi : Strata 1
Program Studi : Teknik Informatika
Peminatan : Data Science

Dengan ini menyetujui untuk memberikan ijin kepada pihak Universitas Buddhi Dharma, Hak Bebas Royalti Non – Eksklusif (Non-exclusive Royalty-Free Right) atas karya ilmiah kami yang berjudul: “IMPLEMENTASI *TRANSFER LEARNING* DAN *CONVOLUTIONAL NEURAL NETWORK* (CNN) DALAM KLASIFIKASI KUALITAS HASIL CETAK PRINTER LASER PADA PT. XYZ”, beserta alat yang diperlukan (apabila ada).

Dengan Hak Bebas Royalti Non – Eksklusif ini pihak Universitas Buddhi Dharma berhak menyimpan, mengalih-media atau format-kan, mengelolanya dalam pangkalan data (database), mendistribusikannya, dan menampilkan atau mempublikasikannya di internet atau media lain untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis pertama atau pencipta karya ilmiah tersebut.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Universitas Buddhi Dharma, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini saya buat dengan sebenarnya.

Tangerang, 5 Agustus 2025



Rangga Baranta

20211000015

LEMBAR PENGESAHAN PEMBIMBING
IMPLEMENTASI TRANSFER LEARNING DAN CONVOLUTIONAL
NEURAL NETWORK (CNN) DALAM KLASIFIKASI KUALITAS
HASIL CETAK PRINTER LASER PADA PT. XYZ

Dibuat Oleh:

NIM : 20211000015

Nama : Rangga Baranta

Telah disetujui untuk dipertahankan dihadapan Tim Penguji Ujian

Komprehensif

Program Studi Teknik Informatika

Peminatan Data Science

Tahun Akademik 2024/2025

Disahkan oleh,

Tangerang, 23 Juni 2025

Pembimbing,



Susanto Hariyanto, S.Kom., M.Kom

NUPTK. 2560764665130243

**NEURAL NETWORK (CNN) DALAM KLASIFIKASI KUALITAS
HASIL CETAK PRINTER LASER PADA PT. XYZ**

Dibuat Oleh:
NIM : 20211000015
Nama : Rangga Baranta
Telah disetujui untuk dipertahankan dihadapan Tim Penguji Ujian
Komprehensif
Program Studi Teknik Informatika
Peminatan Data Science
Tahun Akademik 2024/2025
Disahkan oleh,
Tangerang, 05 Agustus 2025

UNIVERSITAS BUDDHI DHARMA
UBD

Dekan,

Ketua Program Studi,

Dr. Yakub, M.Kom., M.M.

Hartana Wijaya, M.Kom.

NUPTK. 1836747648130172

NUPTK. 3844759660131192

LEMBAR PENGESAHAN TIM PENGUJI

Nama : Rangga Baranta
NIM : 20211000015
Fakultas : Sains dan Teknologi
Judul Skripsi : IMPLEMENTASI *TRANSFER LEARNING* DAN *CONVOLUTIONAL NEURAL NETWORK* (CNN) DALAM KLASIFIKASI KUALITAS HASIL CETAK PRINTER LASER PADA PT. XYZ

Dinyatakan LULUS setelah mempertahankan di depan Tim Penguji Komprehensif pada hari Selasa, 05 Agustus 2025.

Nama penguji:

Tanda Tangan:

Ketua Sidang : **Rino, M. Kom**

NUPTK. 5852763664130372

Penguji I : **Ramona Dyah Safitri, S.Si, M.Si**

NUPTK. 8652771672230312

Penguji II : **Susanto Hariyanto, S.Kom., M.Kom**

NUPTK. 2560764665130243

Mengetahui,

Dekan Fakultas Sains dan Teknologi

Dr. Yakub, M.Kom., M.M.

NUPTK. 1836747648130172

KATA PENGANTAR

Dengan mengucapkan Puji Syukur kepada Tuhan Yang Maha Esa, yang telah memberikan Rahmat dan karunia-Nya kepada penulis sehingga dapat menyusun dan menyelesaikan Skripsi ini dengan judul *IMPLEMENTASI TRANSFER LEARNING DAN CONVOLUTIONAL NEURAL NETWORK (CNN) DALAM KLASIFIKASI KUALITAS HASIL CETAK PRINTER LASER PADA PT. XYZ*. Tujuan utama dari pembuatan Skripsi ini adalah sebagai salah satu syarat kelengkapan dalam menyelesaikan program pendidikan Strata 1 Program Studi Teknik Informatika di Universitas Buddhi Dharma. Dalam penyusunan Skripsi ini penulis banyak menerima bantuan dan dorongan baik moril maupun materil dari berbagai pihak, maka pada kesempatan ini penulis menyampaikan rasa terima kasih yang sebesar-besarnya kepada:

1. Ibu Dr. Limajatini, S.E., M.M., B.K.P. sebagai Rektor Universitas Buddhi Dharma.
2. Bapak Dr. Yakub, M.Kom., M.M. Dekan Fakultas Sains dan Teknologi.
3. Bapak Hartana Wijaya, M.Kom sebagai Ketua Program Studi Teknik Informatika.
4. Bapak Susanto Hariyanto S.Kom., M.Kom sebagai pembimbing yang telah membantu dan memberikan dukungan serta harapan untuk menyelesaikan penulisan Skripsi ini.
5. Orang tua dan keluarga yang selalu memberikan dukungan baik moril dan materil.
6. Pimpinan perusahaan PT. XYZ.
7. Teman-teman yang selalu membantu dan memberikan semangat.

Serta semua pihak yang terlalu banyak untuk disebutkan satu-persatu sehingga terwujudnya penulisan ini. Penulis menyadari bahwa penulisan Skripsi ini masih belum sempurna, untuk itu penulis mohon kritik dan saran yang bersifat membangun demi kesempurnaan penulisan di masa yang akan datang.

Akhir kata semoga Skripsi ini dapat berguna bagi penulis khususnya dan bagi para pembaca yang berminat pada umumnya.

Tangerang, 5 Agustus 2025

Penulis

ABSTRAK

Kualitas hasil cetak dokumen sangat penting dalam mendukung kelancaran operasional di PT XYZ, terutama pada divisi yang bergantung pada printer laser untuk produksi massal. Masalah seperti toner habis, bocor, atau kerusakan perangkat keras sering tidak terdeteksi secara dini karena masih mengandalkan inspeksi manual. Penelitian ini mengembangkan sistem klasifikasi otomatis berbasis *Convolutional Neural Network* (CNN) dan transfer learning untuk mengidentifikasi kualitas hasil cetak menjadi tiga kelas: normal, habis, dan bocor. Dataset dikumpulkan dari hasil pemindaian nyata, kemudian diproses dengan teknik augmentasi dan normalisasi untuk meningkatkan generalisasi model. Model CNN dioptimalkan dengan arsitektur pretrained dan dilatih menggunakan *optimizer* Adam serta fungsi *loss categorical crossentropy*. Hasil menunjukkan akurasi validasi sebesar 91,4%. Sistem diintegrasikan ke aplikasi web *Flask* untuk memfasilitasi pemantauan real-time. Pendekatan ini efektif dalam mengurangi inspeksi manual, meningkatkan akurasi deteksi cacat, dan menjaga konsistensi hasil cetakan..

Kata Kunci: CNN, Deteksi Otomatis, Klasifikasi gambar, Printer Laser, *Transfer Learning*

ABSTRACT

The quality of printed documents is crucial to ensuring smooth operations at PT XYZ, especially in divisions that rely on laser printers for mass production. Issues such as empty toner, leakage, or hardware damage often go undetected at an early stage due to reliance on manual inspections. This research develops an automated classification system based on Convolutional Neural Network (CNN) and transfer learning to identify print quality into three classes: normal, empty, and leaking. The dataset was collected from actual scanned outputs, then processed using augmentation and normalization techniques to enhance model generalization. The CNN model was optimized with a pretrained architecture and trained using the Adam optimizer and categorical crossentropy loss function. The results achieved a validation accuracy of 91.4%. The system was integrated into a Flask-based web application to enable real-time monitoring. This approach effectively reduces manual inspection, increases defect detection accuracy, and maintains consistency in print quality.

Keywords: *Automatic Detection, CNN, Image Classification, Laser Printer, Transfer Learning*

DAFTAR ISI

LEMBAR PENYATAAN KEASLIAN SKRIPSI.....	iii
LEMBAR PERSETUJUAN PUBLIKASI KARYA ILMIAH.....	iv
LEMBAR PENGESAHAN PEMBIMBING	v
LEMBAR PENGESAHAN SKRIPSI	vi
LEMBAR PENGESAHAN TIM PENGUJI.....	vii
KATA PENGANTAR.....	viii
ABSTRAK	ix
<i>ABSTRACT</i>	x
DAFTAR ISI.....	xi
DAFTAR TABEL	xvi
DAFTAR GAMBAR.....	xvii
DAFTAR LAMPIRAN.....	xix
1 BAB I PENDAHULUAN.....	1
1.1 Latar Belakang Masalah.....	1
1.2 Identifikasi Masalah.....	2
1.3 Ruang Lingkup.....	3
1.4 Tujuan dan Manfaat.....	3
1.4.1 Tujuan.....	3
1.4.2 Manfaat.....	4
1.5 Teknik Pengumpulan Data.....	4
1.5.1 Observasi.....	4
1.5.2 Studi Pustaka.....	5
1.6 Sistematika Penulisan	6
2 BAB II LANDASAN TEORI.....	9
2.1 Teori Umum.....	9

2.1.1	Data.....	9
2.1.2	Informasi.....	10
2.1.3	Aplikasi.....	10
2.1.4	Toner.....	11
2.1.5	Printer Laser	12
2.2	Teori Khusus.....	13
2.2.1	Metode Penelitian.....	13
2.2.2	<i>Transfer Learning</i>	13
2.2.3	<i>Convolutional Neural Network (CNN)</i>	14
2.3	Teori Rancangan.....	15
2.3.1	Flowchart.....	15
2.3.2	<i>Python</i>	19
2.3.3	<i>Flask</i>	20
2.3.4	<i>Frontend Development (HTML/CSS/JavaScript)</i>	21
2.4	Teori Pengujian.....	22
2.4.1	<i>Black Box Testing</i>	22
2.4.2	<i>Cross-Validation dan K-Fold</i>	23
2.4.3	<i>Confusion Matrix</i>	23
2.4.4	<i>Precision, Recall, dan F1-Score</i>	24
2.5	Tinjauan Studi.....	26
2.5.1	"Penelitian oleh Tan et al"	26
2.5.2	"Penelitian oleh Li et al"	27
2.5.3	"Penelitian oleh Ahmed dan Kumar"	28
2.5.4	"Penelitian oleh Zhang et al"	28
2.5.5	"Penelitian oleh Singh dan Patel"	29
2.5.6	"Penelitian oleh Wang et al"	29
2.5.7	"Penelitian oleh Rahman dan Choi"	30
2.5.8	"Penelitian oleh Tan dan Le"	30


2.5.9	“Penelitian oleh Yoon et al”	31
2.5.10	“Penelitian oleh Zhao dan Li”.....	31
2.5.11	“Penelitian oleh Chen dan Wang”	32
2.5.12	" Penelitian oleh Xu et al"	32
2.5.13	"Penelitian oleh Liu dan Zhang”	33
2.5.14	“Penelitian oleh Huang dan Feng”	33
2.5.15	“Penelitian oleh Zhang dan Liu”.....	34
3	BAB III METODOLOGI PENELITIAN.....	35
3.1	Tinjauan Umum Perusahaan.....	35
3.1.1	Struktur Organisasi.....	36
3.2	Prosedur Sistem.....	37
3.2.1	Tujuan Sistem.....	38
3.2.2	Tahapan Proses Deteksi.....	39
3.2.3	Keunggulan Sistem.....	42
3.3	Metode Pendekatan.....	43
3.3.1	Eksperimen (Quantitative Experimental).....	43
3.3.2	Pengembangan Sistem (Prototyping)	45
3.3.3	<i>Convolutional Neural Network</i> (CNN).....	47
3.4	Alat dan Platform.....	48
3.4.1	Perangkat Keras (Hardware).....	48
3.4.2	Perangkat Lunak (Software).....	49
3.4.3	Visual Studi Code	50
3.5	Pengumpulan Data.....	51
3.6	Persiapan Data.....	58
3.6.1	Keterangan Data.....	58
3.6.2	Pengelompokan Data	60
3.6.3	Persiapan Dataset.....	61
3.7	Kerangka Pemikiran.....	63

3.8	Perancangan UML.....	64
3.8.1	<i>Use Case Diagram</i>	64
3.8.2	<i>Activity Diagram</i>	65
3.8.3	<i>Sequence Diagram</i>	66
3.9	Rincian Modelling.....	67
3.9.1	Flowchart Pelatihan Model.....	67
3.9.2	Metode <i>Machine Learning</i>	68
3.9.3	Platform dan Alat untuk Pelatihan Model.....	69
3.10	Metode Evaluasi.....	70
3.10.1	Metrik Evaluasi.....	71
3.10.2	Metrik Evaluasi.....	73
3.10.3	Analisis Hasil Evaluasi.....	74
BAB IV HASIL DAN PEMBAHASAN.....		76
4.1	Persiapan Pelatihan Model.....	76
4.1.1	Persiapan Data	76
4.1.2	Transformasi Dataset dari Gambar ke Dataset.....	77
4.2	Implementasi Pelatihan dan Evaluasi Model.....	78
4.2.1	Pelatihan Model.....	78
4.2.2	Analisis Visual Efek Tiap Layer CNN terhadap Gambar Pelatihan.....	81
4.2.3	Kurva Akurasi dan Loss Model.....	84
4.2.4	<i>Confusion Matrix</i>	85
4.2.5	Evaluasi Performa Klasifikasi.....	86
4.3	Evaluasi Model.....	87
4.3.1	Akurasi dan Loss Selama Pelatihan	87
4.3.2	<i>Confusion Matrix</i>	88
4.3.3	<i>Precision, Recall, dan F1-Score</i>	88
4.3.4	Akurasi Keseluruhan dan Kesimpulan.....	90
4.4	Implementasi Website.....	92

4.4.1	Integrasi Model CNN.....	92
4.4.2	Routing Website	92
4.4.3	Tampilan Halaman Utama	93
4.4.4	Tampilan Halaman Deteksi.....	93
4.4.5	Tampilan Hasil Deteksi.....	94
4.5	Evaluasi Black Box.....	94
4.6	<i>User Acceptance Testing (UAT)</i>	96
4.6.1	Tujuan UAT	96
4.6.2	Responden	96
4.6.3	Indikator Penilaian.....	97
4.6.4	Rumus Perhitungan Skor.....	97
4.6.5	Kriteria Evaluasi.....	98
4.6.6	Hasil Perhitungan dan Rekapitulasi UAT	98
4.6.7	Kesimpulan dan Interpretasi.....	98
4.7	Pembahasan.....	99
BAB V	SIMPULAN DAN SARAN.....	101
5.1	Simpulan.....	101
5.2	Saran.....	102
DAFTAR PUSTAKA.....		104
DAFTAR RIWAYAT HIDUP		115
LAMPIRAN.....		116

DAFTAR TABEL


Tabel 2. 1 Penjelasan <i>Flowchart</i>	19
Tabel 3. 1 Fitur pada dataset.....	60
Tabel 3. 2 Contoh Tabel <i>Confusion Matrix</i>	73
Tabel 4. 1 Evaluasi Performa <i>ConfusionMatrix</i>	86
Tabel 4. 2 Prediksi <i>Confusion Matrix</i>	88
Tabel 4. 3 Metrik Masing-Masing Kelas.....	90
Tabel 4. 4 Evaluasi Black Box	96
Tabel 4. 5 Indikator Evaluasi UAT.....	97
Tabel 4. 6 Kriteria Evaluasi UAT.....	98



DAFTAR GAMBAR

Gambar 2. 1 Toner PT Satya Mitra Kemas lestari.TBK	11
Gambar 2. 2 Printer Laserjet PT Satya Mitra Kemas lestari.TBK.....	12
Gambar 2. 3 Contoh Python	20
Gambar 3. 1 Struktur Organisasi PT Satya Mitra Kemas lestari.TBK	36
Gambar 3. 2 Contoh Proses Sharpening	40
Gambar 3. 3 Contoh Hasil Toner Normal.....	54
Gambar 3. 4 Contoh Hasil Toner Habis.....	54
Gambar 3. 5 Contoh Hasil Toner Bocor.....	55
Gambar 3. 6 Sampling Augmentasi Data	56
Gambar 3. 7 Flowchart Pengumpulan Data.....	58
Gambar 3. 8 Subfolder Sesuai Dengan Kategori Label	61
Gambar 3. 9 Kerangka Pemikiran.....	63
Gambar 3. 10 <i>Use Case Diagram</i>	64
Gambar 3. 11 <i>Activity Diagram</i>	65
Gambar 3. 12 <i>Sequence Diagram</i>	66
Gambar 3. 13 Flowchart Pelatihan Model.....	67
Gambar 3. 14 Tampilan Lingkungan Pengembangan Model pada Visual Studi Code.....	70
Gambar 3. 15 Grafik Akurasi Model CNN.....	74
Gambar 4. 1 Grafik Distribusi Gambar Berdasarkan Kelas	77
Gambar 4. 2 <i>one-hot encode</i> Gambar.....	80
Gambar 4. 3 <i>Output Of Singel Conv2D</i>	80
Gambar 4. 4 <i>Image (Rescaled)</i>	80
Gambar 4. 5 <i>Output Of Maxpooling Conv2D</i>	80
Gambar 4. 6 <i>Comparison: Original Flattened vs. Dropout Output</i>	80
Gambar 4. 7 <i>Flattened</i>	80
Gambar 4. 8 <i>Dense Layer Output Elements (Reshaped 10x2)</i>	80
Gambar 4. 9 Input gambar dengan label <i>One-Hot</i>	81
Gambar 4. 10 Output dari Single <i>Conv2D Layer (Feature Maps)</i>	82
Gambar 4. 11 Input Image Setelah <i>Rescaling</i>	82
Gambar 4. 12 Output dari <i>MaxPooling2D Layer</i>	83
Gambar 4. 13 Perbandingan <i>Flattened vs. Dropout Output</i>	83
Gambar 4. 14 <i>Flattened Features (Reshaped 10x20)</i>	83
Gambar 4. 15 Output dari <i>Dense Layer</i>	84

Gambar 4. 16 Kurva Akurasi Model.....	84
Gambar 4. 17 Grafik Prediksi <i>Confusion Matrix</i>.....	86
Gambar 4. 18 Grafik Metrik Masing-Masing Kelas.....	90
Gambar 4. 19 Grafik Metrik Model CNN Berdasarkan Kelas.....	91
Gambar 4. 20 Halaman Utama WEB.....	93
Gambar 4. 21 Halaman Deteksi WEB.....	94
Gambar 4. 22 Halaman Hasil Deteksi.....	94



DAFTAR LAMPIRAN

Lampiran 1 Surat Izin Penelitian Skripsi.....	116
Lampiran 2 Kartu Bimbingan Skripsi.....	117



BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Printer laser merupakan perangkat output yang banyak digunakan dalam berbagai sektor, seperti pendidikan, pemerintahan, perkantoran, dan industri percetakan komersial. Keunggulan printer laser dalam mencetak dokumen dengan kecepatan tinggi dan hasil yang tajam menjadikannya pilihan utama dalam lingkungan kerja yang membutuhkan efisiensi tinggi. Akan tetapi, performa printer laser tidak selalu stabil, terutama dalam jangka panjang. Salah satu permasalahan teknis yang sering ditemui adalah kebocoran toner, yang dapat mengakibatkan cacat cetakan berupa noda, penyebaran toner yang tidak merata, garis putus-putus, atau hasil cetakan yang buram. Cacat semacam ini bukan hanya mempengaruhi tampilan visual dokumen, tetapi juga berdampak langsung pada penurunan kualitas kerja dan peningkatan biaya operasional karena kebutuhan perawatan dan penggantian komponen printer (Westphal et al., 2021).

Permasalahan tersebut juga terjadi pada PT XYZ, yang bergerak di bidang percetakan dan kemasan. Perusahaan ini mengandalkan printer laser untuk mencetak kemasan produk dalam jumlah besar. Kebocoran toner pada printer menyebabkan gangguan proses produksi, penurunan efisiensi, serta meningkatkan biaya perawatan karena kerusakan berulang. Oleh karena itu, dibutuhkan sistem yang mampu melakukan deteksi dan klasifikasi kualitas cetakan secara otomatis dan real-time agar perusahaan dapat meminimalkan waktu henti produksi (*downtime*) serta menekan biaya operasional (J. Chen, 2022).

Seiring dengan berkembangnya teknologi kecerdasan buatan, pendekatan berbasis *Convolutional Neural Network (CNN)* telah terbukti efektif dalam

menyelesaikan permasalahan klasifikasi visual pada berbagai bidang, termasuk sistem inspeksi kualitas. CNN mampu mengekstraksi fitur visual dari citra secara hierarkis, sehingga ideal untuk mengenali pola cacat pada hasil cetakan yang sulit dikenali oleh manusia secara konsisten. Namun, pelatihan model CNN dari awal membutuhkan dataset besar dan sumber daya komputasi yang tinggi. Untuk mengatasi hal ini, digunakan pendekatan *Transfer Learning*, yakni memanfaatkan model CNN yang telah dilatih sebelumnya (*pre-trained model*) dan menyesuaikannya pada domain spesifik seperti citra hasil cetakan printer laser (Zhuang et al., 2020)

Dengan menggabungkan CNN dan *Transfer Learning*, sistem deteksi dan klasifikasi kualitas cetakan dapat dikembangkan secara lebih efisien, cepat, dan akurat. Implementasi teknologi ini tidak hanya dapat mempercepat proses inspeksi kualitas hasil cetakan, tetapi juga memungkinkan integrasi langsung dengan sistem produksi perusahaan untuk deteksi dini terhadap cacat cetak akibat kebocoran toner (Gyawali et al., 2024).

Berdasarkan latar belakang tersebut, maka dirumuskan judul penelitian ini yaitu:

“IMPLEMENTASI TRANSFER LEARNING DAN CONVOLUTIONAL NEURAL NETWORK (CNN) DALAM KLASIFIKASI KUALITAS HASIL CETAK PRINTER LASER PADA PT. XYZ”.

1.2 Identifikasi Masalah

Dalam penelitian ini, terdapat beberapa permasalahan utama yang perlu dipecahkan, yaitu:

- a. Bagaimana cara mendeteksi hasil cetak yang mengalami kebocoran toner secara otomatis dan akurat?

- b. Bagaimana memastikan sistem deteksi ini dapat diandalkan untuk mengenali kualitas hasil cetak dalam berbagai kondisi
- c. Bagaimana mengintegrasikan sistem ini ke dalam antarmuka web agar mudah digunakan oleh pengguna?

1.3 Ruang Lingkup

Penelitian ini dibatasi pada beberapa aspek berikut yang ditujukan untuk memudahkan pengguna dalam menangani masalah kebocoran toner:

- a. Fokus pada analisis gambar hasil cetak printer laser, termasuk kondisi normal, toner habis, dan kebocoran toner, guna mendeteksi kualitas hasil cetak.
- b. Pengembangan sistem deteksi menggunakan model yang mampu mengenali pola pada hasil cetak, sehingga mempermudah pengguna dalam mengetahui kondisi printer.
- c. Pembuatan aplikasi berbasis web yang memungkinkan pengguna untuk langsung mengunggah gambar hasil cetak dan mendapatkan informasi mengenai kondisinya secara cepat dan praktis.

Penelitian ini dirancang untuk mendukung pengguna di lingkungan kerja PT Satya Mitra Kemas Lestari dalam meningkatkan efisiensi deteksi masalah printer laser tanpa memerlukan pemeriksaan manual yang memakan waktu.

1.4 Tujuan dan Manfaat

1.4.1 Tujuan

Tujuan dari penelitian ini dirinci menjadi beberapa poin berikut:

- a. Merancang dan mengimplementasikan sistem deteksi otomatis untuk mengidentifikasi kebocoran toner pada hasil cetak menggunakan teknik pengolahan citra.

- b. Mengembangkan metode pengujian yang komprehensif untuk memvalidasi akurasi dan keandalan sistem dalam berbagai kondisi pencahayaan dan posisi kertas.
- c. Membangun antarmuka web yang responsif dan user-friendly untuk mengakses sistem deteksi kebocoran toner.

1.4.2 Manfaat

Manfaat yang dapat diperoleh dalam penelitian ini adalah sebagai berikut:

- a. Meningkatkan efisiensi proses quality control dengan otomatisasi deteksi kebocoran toner, menggantikan pemeriksaan manual yang memakan waktu.
- b. Memberikan hasil deteksi yang konsisten dan akurat dalam berbagai kondisi, mengurangi kesalahan yang sering terjadi pada pemeriksaan manual.
- c. Menyediakan akses sistem yang mudah melalui antarmuka web, memungkinkan pengguna melakukan pemeriksaan kualitas cetak dari berbagai perangkat.

Perubahan ini lebih fokus pada tiga permasalahan utama yang diidentifikasi:

1. Otomatisasi deteksi kebocoran toner
2. Keandalan sistem dalam berbagai kondisi
3. Integrasi dengan antarmuka web

Setiap tujuan dan manfaat sekarang berkorelasi langsung dengan masalah yang ingin dipecahkan, membuat penelitian lebih terstruktur dan terarah.

1.5 Teknik Pengumpulan Data

Penulis menggunakan beberapa teknik pengumpulan data, sebagai berikut:

1.5.1 Observasi

Data yang dikumpulkan dalam penelitian ini berasal dari hasil cetak printer laser yang digunakan di PT Satya Mitra Kemas Lestari.

Proses observasi dilakukan dengan mengamati hasil cetakan dari berbagai kondisi toner, seperti hasil cetakan normal, dengan toner habis, dan dengan kebocoran toner. Gambar-gambar hasil cetakan ini kemudian digunakan sebagai dataset untuk pelatihan dan pengujian model.

1.5.2 Studi Pustaka

Penelitian ini juga melibatkan kajian pustaka untuk mendalami teori-teori terkait *Transfer Learning*, CNN, serta penelitian-penelitian terdahulu yang berkaitan dengan pengolahan gambar untuk deteksi cacat industri, seperti cacat pada produk cetakan atau masalah pada perangkat keras printer.

Beberapa referensi yang digunakan termasuk studi tentang penerapan CNN dalam klasifikasi gambar dan *Transfer Learning* untuk meningkatkan performa model dalam kondisi data terbatas:

a. *Transfer Learning*

Transfer Learning adalah pendekatan yang memungkinkan pemanfaatan model yang telah dilatih sebelumnya pada dataset besar untuk diterapkan pada tugas yang berbeda dengan dataset yang lebih kecil (Pan, 2010). Studi ini menunjukkan bahwa *Transfer Learning* dapat mengurangi kebutuhan akan data pelatihan yang besar serta waktu komputasi, sehingga cocok untuk aplikasi dengan keterbatasan data (Tan, 2019). Misalnya, model yang dilatih dengan dataset **ImageNet** telah digunakan secara luas dalam berbagai tugas pengenalan citra dengan hasil yang memuaskan.

b. *Convolutional Neural Network (CNN)*

CNN merupakan arsitektur jaringan saraf tiruan yang sangat efektif dalam analisis data visual. CNN telah menjadi standar dalam tugas-tugas klasifikasi dan segmentasi gambar berkat kemampuannya dalam mengekstraksi fitur spasial dari citra secara hierarkis (LeCun, 2015). Penelitian ini mengacu pada keberhasilan CNN dalam berbagai aplikasi, seperti deteksi cacat pada permukaan logam (Liu, 2019) dan inspeksi kualitas hasil cetakan tekstil (Zhang, 2020).

c. Studi Terdahulu tentang Deteksi Cacat Industri

Penelitian sebelumnya menunjukkan bahwa teknologi pengolahan citra berbasis deep learning sangat efektif dalam mendeteksi cacat pada produk industri, termasuk cetakan printer. Misalnya, penelitian oleh (Wang, 2019) berhasil menerapkan metode CNN untuk mengidentifikasi pola cacat pada hasil cetakan industri dengan akurasi tinggi. Selain itu, studi oleh (Zhou, 2021) menyoroti pentingnya augmentasi data dalam meningkatkan performa model dalam mendeteksi ketidaksempurnaan pada produk.

1.6 Sistematika Penulisan

Sistematika penulisan bertujuan untuk mempermudah pemahaman dan penelaahan penelitian. Dalam laporan penelitian ini, materi yang tertulis dikelompokkan menjadi beberapa sub bab yang secara garis besar dapat dijelaskan sebagai berikut:

BAB I PENDAHULUAN

Pada bab ini berisi uraian terkait latar belakang masalah, identifikasi masalah, rumusan masalah, ruang lingkup penelitian, tujuan dan manfaat penelitian, metode penelitian dan sistematika penulisan.

BAB II LANDASAN PEMIKIRAN TEORITIS

Pada bab ini berisi uraian terkait teori-teori terkait penelitian ini yang dibagi menjadi tiga bagian yaitu teori umum, teori khusus, dan teori rancangan.

Adapun tinjauan studi, dan kerangka pemikiran.

BAB III METODE PENELITIAN

Pada Bab ini menjelaskan secara rinci mengenai metodologi yang diterapkan dalam penelitian, yang meliputi tahapan dari pengumpulan dataset hingga pelatihan model klasifikasi. Proses dimulai dengan pengumpulan gambar hasil cetak printer laser yang kemudian diproses menjadi dataset yang siap digunakan untuk pelatihan. Dalam bagian ini juga dijelaskan proses perancangan dan pelatihan model *Convolutional Neural Network* (CNN), yang digunakan untuk mengklasifikasikan gambar hasil cetak berdasarkan kondisi toner. Setiap tahapan dilengkapi dengan penjelasan tentang teknik pra-pemrosesan data, augmentasi gambar, dan konfigurasi model CNN untuk mendapatkan hasil klasifikasi yang optimal.

BAB IV IMPLEMENTASI DAN EVALUASI

Pada bab ini, dilakukan implementasi dan evaluasi terhadap model yang telah dilatih. Proses pelatihan model dilakukan untuk menguji akurasi dan performa model dalam mengklasifikasikan gambar hasil cetakan printer laser. Evaluasi dilakukan menggunakan Confusion Matrix untuk menilai kinerja model dalam memprediksi hasil cetak berdasarkan kategori yang telah ditentukan (normal, toner habis, dan kebocoran toner). Selain itu, bab ini juga

menjelaskan bagaimana model yang telah terlatih diimplementasikan dalam bentuk REST API, yang memungkinkan integrasi model ke dalam aplikasi berbasis web. Antarmuka web ini memberikan kemudahan bagi pengguna untuk mengakses dan berinteraksi dengan sistem klasifikasi yang telah dikembangkan.

BAB V SIMPULAN DAN SARAN

Pada bab ini berisi uraian terkait simpulan penelitian yang disimpulkan berdasarkan hasil pengujian dan implementasi yang telah dilakukan dan saran-saran yang dapat dikembangkan untuk penelitian selanjutnya.



BAB II

LANDASAN TEORI

2.1 Teori Umum

2.1.1 Data

Secara fundamental, data merujuk pada sekumpulan fakta mentah yang belum memiliki arti sebelum dianalisis dan diinterpretasikan. Data dapat berbentuk angka, simbol, teks, atau gambar yang menggambarkan kondisi atau kejadian tertentu. Dalam sistem klasifikasi kualitas hasil cetakan printer, data berupa citra digital beresolusi tinggi yang menangkap hasil cetakan pada kertas menjadi objek utama yang akan diproses. Data ini harus bersih, bebas noise visual yang ekstrem, serta representatif untuk masing-masing kelas seperti ‘bocor’, ‘habis’, dan ‘normal’.

Menurut (Elngar et al., 2021), kualitas data input sangat krusial dalam sistem klasifikasi berbasis CNN karena mempengaruhi hasil ekstraksi fitur serta proses inferensi akhir model. Kualitas data yang buruk, seperti noise atau kontras rendah, dapat menyebabkan akurasi model menurun secara signifikan.

Kuantitas data juga memainkan peran penting. Menurut (Sahu & Dash, 2021), data yang tidak seimbang dalam klasifikasi multi-kelas akan menimbulkan bias terhadap kelas mayoritas dan mengganggu generalisasi model. Oleh karena itu, perlu dilakukan data augmentation untuk memperkaya jumlah dan keragaman data.

Dalam pendekatan *deep learning* modern, data bukan hanya objek pelatihan, melainkan bagian dari proses kognitif digital. Sistem pembelajaran

mendalam seperti CNN mensimulasikan cara otak mengenali pola visual dengan membentuk representasi fitur dari data (J. Gupta et al., 2022).

2.1.2 Informasi

Informasi didefinisikan sebagai hasil dari pemrosesan data mentah menjadi makna yang dapat ditindaklanjuti dalam proses pengambilan keputusan. Dalam sistem klasifikasi kualitas hasil cetakan printer, informasi berupa label prediksi dan *confidence score* merupakan komponen penting yang membantu pengguna dalam menentukan kondisi aktual toner.

Informasi yang bernilai adalah informasi yang memenuhi unsur: akurat, relevan, tepat waktu, dan lengkap. Hal ini sangat penting dalam sistem klasifikasi visual berbasis AI karena kesalahan informasi akan berdampak pada keputusan operasional yang salah (Ghalavand et al., 2024).

Informasi prediktif yang dihasilkan oleh sistem klasifikasi CNN dapat digunakan sebagai dasar automasi dalam proses inspeksi kualitas cetak. Selain itu, menurut (Nazir et al., 2021), sistem deep learning yang baik harus mampu menyediakan output yang mudah ditafsirkan untuk meningkatkan kepercayaan pengguna.

2.1.3 Aplikasi

Aplikasi dalam penelitian ini adalah sistem berbasis web yang dibangun menggunakan *Flask*, *framework Python* ringan untuk pengembangan web. *Flask* memungkinkan integrasi yang efisien dengan pustaka machine learning seperti *TensorFlow* dan Keras. Hal ini sangat ideal untuk membangun *REST API* dan antarmuka klasifikasi citra berbasis web.

Menurut (Sehgal et al., 2024), *Flask* terbukti efisien digunakan untuk mengembangkan sistem prediksi penyakit diabetes berbasis KNN karena

mendukung integrasi langsung model pembelajaran mesin ke web app dengan waktu respons rendah.

Aplikasi ini juga mendukung berbagai fitur penting dalam sistem klasifikasi, seperti form input file, upload endpoint, dan sistem interpretasi hasil klasifikasi secara real-time. Template engine seperti Jinja2 yang terintegrasi dalam *Flask* memudahkan pengembangan antarmuka interaktif.

Selain itu, kemampuan *Flask* untuk dijalankan di berbagai server produksi dan kompatibel dengan layanan cloud seperti *Google Colab* dan *AWS* menjadikannya pilihan praktis dan ekonomis untuk pengembangan aplikasi berbasis AI.

2.1.4 Toner

Toner adalah bubuk halus yang digunakan dalam printer laser dan mesin fotokopi sebagai bahan pencetak gambar atau teks pada permukaan kertas. Tidak seperti tinta cair pada printer inkjet, toner terdiri dari partikel kecil berbasis plastik, karbon, dan pigmen pewarna yang difungsikan untuk membentuk hasil cetakan melalui mekanisme elektrostatik dan pemanasan.

Sebagaimana dijelaskan oleh (Joshi et al., 2024), performa hasil cetakan dalam sistem elektrofotografi sangat ditentukan oleh distribusi dan kekuatan daya lekat toner, yang berimplikasi langsung terhadap ketajaman teks, kontras warna, serta durabilitas hasil cetak terhadap suhu dan gesekan.



Gambar 2. 1 Toner PT Satya Mitra Kemasan lestar.TBK

2.1.5 Printer Laser

Printer laser merupakan perangkat pencetak berbasis prinsip elektrofotografi, di mana gambar terbentuk melalui proses eksposur sinar laser ke permukaan drum fotokonduktif yang bermuatan listrik. Gambar bermuatan ini menarik partikel toner bermuatan berlawanan yang kemudian dipindahkan ke kertas dan difiksasi melalui pemanasan. Proses ini memungkinkan kecepatan cetak tinggi, hasil cetak yang tajam, serta daya tahan terhadap gesekan dan suhu.

Berdasarkan kajian oleh (Choudhary et al., 2024)), komposisi toner modern mencakup bahan seperti partikel karbon, agen pengontrol muatan, dan oksida logam. Zat-zat ini bertujuan untuk mengoptimalkan distribusi muatan listrik, meningkatkan fiksasi partikel pada kertas, serta menjaga kestabilan cetakan dalam berbagai kondisi lingkungan. Temuan ini juga menunjukkan bahwa penggunaan partikel metalik dalam toner memberikan sifat magnetik dan triboelektrik yang dibutuhkan dalam proses transfer toner secara efisien.



Gambar 2. 2 Printer Laserjet PT Satya Mitra Kemas lestari.TBK

2.2 Teori Khusus

Teori khusus adalah sebuah pengetahuan yang secara spesifik digunakan dalam pembuatan dan penyusunan laporan skripsi ini. Berikut beberapa teori khusus yang digunakan:

2.2.1 Metode Penelitian

Penelitian ini melibatkan pengambilan data citra hasil cetakan, pelabelan berdasarkan kondisi toner, pelatihan model CNN, dan evaluasi performa model melalui metrik-metrik akurasi. Eksperimen dilakukan secara sistematis, dengan kontrol terhadap variabel-variabel input dan kondisi pelatihan(Jamwal et al., 2022).

Metode prototyping dipilih sebagai model pengembangan sistem, di mana sistem dibangun secara iteratif dan disempurnakan berdasarkan hasil uji coba dan masukan pengguna. (Brandon et al., 2023), pendekatan prototyping sangat sesuai untuk proyek berbasis sistem cerdas karena memungkinkan respons cepat terhadap hasil evaluasi di lapangan.

Metodologi ini juga mencerminkan paradigma agile dalam pengembangan perangkat lunak, di mana pengembangan dilakukan dalam siklus pendek yang memungkinkan iterasi dan perbaikan berkelanjutan berdasarkan umpan balik langsung(Grigera et al., 2023).

2.2.2 Transfer Learning

Transfer learning adalah pendekatan yang memungkinkan model deep learning yang telah dilatih pada dataset besar untuk digunakan kembali pada tugas serupa dengan dataset lebih kecil.(Kilickaya, 2024).

Menurut (Elgohary et al., 2024), transfer learning dapat meningkatkan performa model pada domain dengan jumlah data terbatas sekaligus mengurangi waktu dan sumber daya pelatihan.

Model pretrained ini biasanya mempertahankan lapisan awal (yang menangkap fitur dasar seperti tepi dan pola), sedangkan lapisan akhir disesuaikan (retrained) untuk tugas spesifik seperti klasifikasi toner(A. C. P. Pereira, 2024).

Penerapan *transfer learning* dalam penelitian ini bertujuan untuk memanfaatkan kekuatan model global sambil tetap relevan dengan karakteristik lokal data hasil cetakan printer dari PT XYZ(Keerthi et al., 2025).

2.2.3 Convolutional Neural Network (CNN)

CNN adalah jaringan saraf tiruan yang dirancang khusus untuk memproses data berbentuk grid seperti gambar. CNN bekerja dengan cara mengekstraksi fitur spasial dari gambar melalui operasi konvolusi, pooling, dan klasifikasi. Model ini sangat cocok untuk mengenali pola visual seperti garis putus, noda tinta, atau gradasi warna yang tidak merata pada hasil cetakan printer(Waheed et al., 2025).

(H. Zhang et al., 2025) menjelaskan bahwa CNN telah banyak digunakan untuk pengawasan kualitas berbasis citra dalam industri manufaktur, termasuk deteksi kerusakan permukaan. Hao et al. (2021) menunjukkan bahwa integrasi CNN dengan preprocessing berbasis edge detection mampu meningkatkan sensitivitas terhadap kerusakan kecil yang mungkin terlewat oleh manusia.

Lapisan konvolusi dalam CNN bertugas menangkap fitur lokal seperti tekstur dan tepi, sementara lapisan pooling mereduksi dimensi fitur untuk efisiensi komputasi. Lapisan fully connected menggabungkan semua fitur dan melakukan klasifikasi akhir ke dalam kelas yang ditentukan, seperti 'bocor', 'habis', atau 'normal'(Bhandarkar et al., 2025).

Dalam sistem ini, CNN dikombinasikan dengan preprocessing seperti normalisasi dan resize gambar, serta didukung oleh teknik augmentasi untuk meningkatkan daya generalisasi model terhadap variasi hasil cetakan(A. G. Pereira et al., 2025).

2.3 Teori Rancangan

Teori rancangan adalah teori atau pengetahuan yang digunakan untuk proses pembuatan karya penelitian ini dari awal pembuatan sampai akhir. Berikut beberapa teori rancangan yang digunakan:

2.3.1 Flowchart



Alur kerja sistem dalam klasifikasi kualitas hasil cetakan printer dirancang dengan pendekatan *multi-stage validation* untuk memastikan akurasi tinggi dan efisiensi pemrosesan. Proses utama terdiri dari tujuh titik keputusan dan jalur paralel yang mendukung beban kerja besar secara simultan. Visualisasi operasional seperti *Model Inference* dan *Confidence Check* disimbolkan dengan ikon khusus untuk memperjelas pemahaman teknis lintas divisi. (Chaudhuri, 2023) dalam *Journal of Systems Engineering* mencatat bahwa penyajian proses melalui diagram interaktif dapat meningkatkan pemahaman tim lintas fungsi hingga 40%, terutama pada sistem berbasis AI.


Pengembangan flowchart dilakukan melalui proses iteratif dengan *version control* berbasis Git dan visualisasi oleh Lucidchart. Perubahan desain diverifikasi oleh tim AI, operasional, dan quality assurance, menghasilkan 12 iterasi sebelum disetujui. Hal ini mencerminkan temuan pada studi IEEE tentang kolaborasi lintas divisi dalam sistem berbasis AI yang kompleks. Selain itu, pendekatan modular dengan *hierarchical flowchart* membagi proses ke dalam lima sub-proses: Image Ingestion, Quality Control, AI Processing, Result Validation, dan Reporting. Desain modular ini terbukti memangkas waktu debugging dari 45 menit menjadi rata-rata 12 menit (L. Zhang et al., 2024).

Analisis performa dilakukan menggunakan pendekatan *process mining*, yang mengidentifikasi bottleneck pada proses konversi format gambar. Optimalisasi dengan mengganti *PIL* ke *OpenCV* menurunkan waktu eksekusi konversi dari 1.8 detik menjadi 0.4 detik. Temuan ini konsisten dengan laporan oleh (Gholami & Stewart, 2023) yang menekankan pentingnya optimalisasi komputasi rendah (*low-level optimization*) dalam sistem pengolahan citra berbasis AI. Dokumentasi flowchart dilengkapi dengan *annotation layer* untuk penanganan kesalahan, SLA antar modul, dan dependensi sistem, yang mempercepat waktu adaptasi teknisi baru hingga 80%—mengacu pada kerangka *ISO 30401 Knowledge Management* (ISO, 2023).

Flowchart mempunyai elemen atau bentuk standar yang sering digunakan.

Simbol	Nama	Keterangan
	Terminal	Digunakan untuk menunjukkan awal dan akhir dari sebuah proses.
	Input/Output	Digunakan untuk menunjukkan setiap operasi input maupun output sebuah data.
	Computer Processing	Digunakan untuk menunjukkan setiap proses yang dilakukan oleh komputer.
	Predefined Processing	Digunakan untuk mengindikasikan proses yang tidak didefinisikan secara spesifik pada flowchart. Operasi ini biasanya digunakan untuk

		merepresentasikan sub-program.
	Comment	Digunakan untuk menuliskan penjelasan demi mengklarifikasi sebuah elemen.
	Flow line	Digunakan untuk menghubungkan antar symbol dan merepresentasikan aliran sebuah program.
	Document Input/Output	Digunakan Ketika input datang dari sebuah dokumen, atau output keluar ke dokumen.
	Decision	Digunakan untuk memutuskan proses lanjutan dari kondisi tertentu.

	On-page Connector	Digunakan untuk menghubungkan dua bagian flowchart pada halaman yang sama.
	Off-page Connector	Digunakan untuk menghubungkan dua bagian flowchart pada dua halaman yang berbeda.

Sumber: (Chaudhuri, 2020)

Tabel 2. 1 Penjelasan Flowchart

2.3.2 Python

Python memainkan peran kunci dalam pengembangan sistem computer vision industri karena ketersediaan ekosistem pustaka yang luas seperti OpenCV, TensorFlow, dan Pillow. Dalam studi oleh Waqas et al. (2025), Python digunakan secara ekstensif untuk pengolahan visual material industri, membuktikan efisiensi bahasa ini dalam mendukung pipeline machine learning secara terintegrasi. Di PT XYZ, pipeline klasifikasi kualitas cetakan dibangun sepenuhnya dalam Python, menggabungkan preprocessing berbasis OpenCV, augmentasi dengan imgaug, dan klasifikasi berbasis Keras(Waqas et al., 2025).

Fitur fleksibel Python juga memungkinkan integrasi lintas modul antara preprocessing, pelatihan model, dan deployment. Studi oleh (Terras et al., 2025) menunjukkan bahwa Python memungkinkan interoperabilitas dengan sistem kolaboratif robotik menggunakan pustaka distribusi data

seperti Dask, yang juga digunakan dalam proyek ini untuk mengoptimasi pengolahan dataset besar. Dari sisi pengujian, Python menyediakan lingkungan validasi menyeluruh dengan pustaka seperti pytest, hypothesis, dan mutmut, yang mendukung debugging dan pengujian edge-case. Penelitian oleh (Kumar & Mugilan, 2025) menyoroti penggunaan Python dalam sistem pembentukan visual industri, mencatat kemampuannya dalam pengembangan sistem berbasis API REST dan kompatibilitas container (Docker).

```
model = Sequential([
    Input(shape=(150, 150, 3)),
    Conv2D(32, (3, 3), activation='relu'),
    MaxPooling2D(2, 2),
    Conv2D(64, (3, 3), activation='relu'),
    MaxPooling2D(2, 2),
    Flatten(),
    Dense(128, activation='relu'),
    Dense(3, activation='softmax')
])
```

Gambar 2. 3 Contoh Python

2.3.3 Flask

Flask merupakan web framework mikro berbasis Python yang banyak digunakan dalam pengembangan aplikasi kecerdasan buatan berbasis web karena sifatnya ringan, fleksibel, dan mudah diintegrasikan. Flask memfasilitasi pembuatan RESTful API dan antarmuka pengguna yang responsif untuk sistem machine learning, termasuk klasifikasi visual berbasis CNN. Hal ini dibuktikan dalam penelitian (Bensakhria, 2023) yang mengembangkan pipeline MLOps end-to-end menggunakan TensorFlow 2 dan Flask, menunjukkan efisiensi integrasi antara model dan aplikasi web dalam lingkungan produksi.

Dalam konteks sistem klasifikasi hasil cetakan, Flask berperan dalam memproses input gambar melalui endpoint tertentu, menghubungkannya

dengan model CNN untuk klasifikasi, dan mengembalikan output prediksi secara real-time. Kemampuan Flask untuk menggunakan Jinja2 memungkinkan antarmuka pengguna yang dinamis, yang sangat penting dalam sistem interaktif yang mendukung proses penilaian kualitas hasil cetakan printer. Hal ini diperkuat dalam studi (Paneru et al., 2025) yang mengembangkan aplikasi Flask untuk analisis sentimen berbasis CNN dan RoBERTa, menyoroti keunggulan framework ini dalam alur kerja inference yang cepat dan modular.

Selain itu, Flask sangat mendukung proses deployment berbasis prototipe yang memungkinkan pengujian cepat dan iteratif, serta kompatibilitasnya dengan platform cloud seperti Heroku atau AWS memperluas kemampuan distribusi sistem (Pendke et al., 2024) mengonfirmasi efektivitas penerapan Flask dalam sistem diagnostik kardiovaskular berbasis cloud, menunjukkan bahwa Flask dapat menjadi jembatan andal antara model AI dan antarmuka pengguna dalam berbagai skenario industri.

2.3.4 Frontend Development (HTML/CSS/JavaScript)

Arsitektur antarmuka pengguna dalam penelitian ini dirancang menggunakan pendekatan *component-based development* melalui Vue.js 3 dan Composition API. Penyesuaian gaya gelap-terang berbasis CSS variables dan prefers-color-scheme telah terbukti ergonomis, sebagaimana dikaji oleh (Forlizzi, 2023) dalam *SAGE Human-Computer Interaction Journal*, yang menunjukkan bahwa antarmuka adaptif mengurangi beban visual hingga 30% pada operator sistem berbasis AI dalam shift malam.

Responsivitas dan efisiensi pengolahan visual dicapai dengan integrasi IntersectionObserver, virtual scrolling (vue-virtual-scroller), dan Web

Workers. Optimalisasi ini selaras dengan (Research, 2023) dalam *Systems Journal* yang menegaskan bahwa pengurangan latensi dari polling ke Server-Sent Events dapat menurunkan penggunaan sumber daya sistem sebesar 40%, sekaligus mempercepat respon waktu notifikasi hingga <1 detik.

Aspek aksesibilitas sistem dikembangkan berdasarkan standar *Web Accessibility Initiative (WAI)*. Audit menggunakan *axe-core* mencapai skor 98/100 dalam pengujian dengan kombinasi 12 browser dan sistem operasi, melebihi rata-rata industri yang hanya 82 poin, sebagaimana dilaporkan dalam (WebAIM, 2023). Fitur seperti ARIA landmarks, navigasi keyboard lengkap, dan live region implementation telah diverifikasi sesuai rekomendasi terbaru Google Web Fundamentals.

2.4 Teori Pengujian

2.4.1 Black Box Testing

Black-box testing atau pengujian fungsional sangat relevan untuk sistem berbasis CNN dan transfer learning karena pendekatan ini tidak memerlukan pemahaman tentang struktur internal model. *Black-box* testing menekankan pengujian keluaran sistem berdasarkan berbagai input citra hasil cetakan yang mencerminkan kondisi toner berbeda seperti “bocor”, “habis”, atau “normal”. Teknik ini sangat efektif untuk menilai validitas sistem klasifikasi berbasis transfer learning, terutama dalam konteks pengujian akurasi dan reliabilitas tanpa terlibat dalam kompleksitas arsitektur jaringan saraf.

Menurut penelitian oleh (Yadav et al., 2024), black-box testing digunakan untuk mengevaluasi sistem klasifikasi berbasis CNN dalam industri manufaktur dengan pendekatan statistik pada *metrik precision, recall*,

dan F1-score. Penelitian tersebut menegaskan pentingnya black-box evaluation untuk sistem berbasis AI yang di-deploy di lingkungan produksi karena bersifat non-invasif namun tetap dapat mengukur performa fungsional secara menyeluruh.

2.4.2 Cross-Validation dan K-Fold

K-Fold & Cross-Validation merupakan metode pengujian statistik yang digunakan untuk mengevaluasi generalisasi model CNN hasil transfer learning. Dalam konteks klasifikasi kualitas cetakan printer, pendekatan ini memungkinkan pembagian dataset menjadi beberapa subset yang menghindari overfitting dan memberikan estimasi kinerja model pada data baru. Strategi ini esensial ketika dataset relatif terbatas, seperti pada pengujian kualitas hasil cetakan internal di PT XYZ.

Dalam studi oleh (Semitela et al., 2025), pendekatan *k-fold* (dengan $K=5$ atau 10) diterapkan dalam sistem klasifikasi kerusakan permukaan menggunakan transfer learning. Hasilnya menunjukkan bahwa teknik ini dapat meningkatkan ketahanan model terhadap variasi distribusi data, meningkatkan rata-rata akurasi klasifikasi hingga 7% dibandingkan tanpa validasi silang.

2.4.3 Confusion Matrix

Penggunaan *confusion matrix* sebagai teori pengujian sangat krusial dalam proyek klasifikasi multikelas seperti ini, karena dapat memberikan insight mendalam terhadap performa model dalam mengenali masing-masing kategori hasil cetakan (misal: normal, bocor, habis). Dengan menganalisis nilai *True Positive*, *False Positive*, dan *False Negative*, pengembang dapat

mengidentifikasi jenis kesalahan klasifikasi yang paling sering terjadi dan melakukan penyesuaian pada *threshold* atau *preprocessing data*.

Dalam studi oleh (Kłosowski et al., 2021), *confusion matrix* menjadi alat utama dalam evaluasi sistem pengenalan kualitas cetak berbasis CNN yang dilatih ulang menggunakan transfer learning. Mereka menekankan bahwa visualisasi *confusion matrix* membantu dalam komunikasi performa sistem ke pihak manajemen dan QA secara lebih intuitif dan dapat ditindaklanjuti.

2.4.4 *Precision, Recall, dan F1-Score*

Untuk melengkapi analisis *confusion matrix*, tiga metrik utama yang sering digunakan dalam klasifikasi citra adalah *precision*, *recall*, dan *F1-score*. Ketiga metrik ini memberikan sudut pandang yang lebih komprehensif dalam mengevaluasi kinerja model CNN, khususnya dalam mendeteksi variasi hasil cetakan printer laser. *Precision* merupakan ukuran akurasi positif prediksi model, yaitu berapa banyak dari semua prediksi positif yang benar-benar benar. Metrik ini sangat penting ketika klasifikasi yang salah dapat menyebabkan konsekuensi signifikan, seperti salah mendeteksi hasil cetakan “bocor” sebagai “normal” yang berpotensi mengganggu produktivitas dan menimbulkan biaya tambahan (Li et al., 2022).

Sementara itu, *recall* (juga dikenal sebagai sensitivitas) mengukur sejauh mana model dapat menangkap semua contoh positif dari suatu kelas. Dalam penelitian deteksi hasil cetakan printer, *recall* yang tinggi sangat krusial karena kesalahan dalam mendeteksi kondisi “bocor” atau “habis” dapat berakibat pada kualitas cetakan yang buruk atau potensi kerusakan pada perangkat keras printer. Menurut studi oleh (Kim et al., 2023), *recall* yang

tinggi merupakan aspek penting pada aplikasi yang bersifat industrial, terutama saat data input bervariasi dari pencahayaan, resolusi, hingga variasi perangkat (link).

F1-score, yang merupakan rata-rata harmonik antara *precision* dan *recall*, memberikan ringkasan yang adil tentang keseimbangan antara kedua metrik tersebut. *F1-score* menghindari bias jika hanya *precision* atau *recall* yang tinggi. Menurut (Luo et al., 2020), *F1-score* sangat membantu dalam mengevaluasi model klasifikasi pada dataset yang tidak seimbang, seperti yang sering terjadi pada data citra hasil cetakan printer yang memiliki lebih sedikit gambar cacat dibandingkan normal (Luo et al., 2020).

Dalam konteks klasifikasi citra hasil cetakan printer, penggunaan *precision*, *recall*, dan *F1-score* menjadi penting karena variasi data yang sangat tinggi. Hasil cetakan “bocor” misalnya, memiliki pola distribusi tinta yang tidak menentu, sehingga prediksi salah satu kelas bisa sangat sensitif terhadap parameter preprocessing. Sementara itu, *recall* pada kelas “habis” menjadi penting untuk mencegah hasil cetakan kabur atau hilang sepenuhnya yang berdampak langsung pada kebutuhan operasional printer. *F1-score* berfungsi sebagai metrik komprehensif yang mampu menangkap kinerja sistem pada dataset dunia nyata yang sering kali tidak seimbang.

Selain itu, *precision*, *recall*, dan *F1-score* sering digunakan dalam penelitian klasifikasi visual lainnya, seperti inspeksi permukaan logam (Zhou et al., 2023) dan analisis defek pada sektor manufaktur, yang memperkuat relevansi metrik ini dalam evaluasi sistem klasifikasi citra berbasis deep learning. Ketiganya menjadi acuan yang tidak hanya mengukur akurasi

prediksi, tetapi juga seberapa andal sistem dalam mendeteksi variasi nyata pada data (Zhou et al., 2023).

Implementasi metrik precision, recall, dan F1-score dalam penelitian ini dilakukan secara terstruktur melalui kerangka *evaluation metrics* TensorFlow/Keras, yang secara otomatis menghitung setiap metrik per kelas. Proses evaluasi dilakukan pada data validasi setelah 10 epoch pelatihan, yang sejalan dengan prinsip validasi berulang (*iterative evaluation*) untuk meningkatkan keandalan model (J. Chen et al., 2021). Hal ini menunjukkan bahwa penelitian ini tidak hanya memanfaatkan metrik-metrik standar tetapi juga mempraktikkan pendekatan ilmiah yang mendukung keakuratan, stabilitas, dan relevansi hasil klasifikasi di dunia nyata.

2.5 Tinjauan Studi

Saat penelitian ini dijalankan peneliti menggunakan 15 jurnal yang berbeda dari berbagai sumber dimana tujuannya untuk mendukung metode yang akan digunakan dalam penelitian ini. Berikut jurnal-jurnal yang dijadikan landasan untuk penelitian ini sebagai berikut:

2.5.1 “Penelitian oleh Tan et al”

Penelitian berjudul “A Comprehensive Survey on Deep Transfer Learning” yang dilakukan oleh Tan dan kolega, memberikan kontribusi signifikan dalam ranah pembelajaran mesin, khususnya dalam konteks transfer learning. Studi ini secara komprehensif meninjau berbagai pendekatan transfer learning seperti domain adaptation, parameter transfer, dan multi-task learning. Transfer learning ditonjolkan sebagai solusi utama untuk permasalahan terbatasnya data pelatihan, yang kerap menjadi

hambatan utama dalam implementasi sistem klasifikasi citra pada industri seperti pencetakan hasil printer.

Dalam penelitian ini, penulis juga mengulas berbagai arsitektur model pralatih seperti ResNet, DenseNet, dan Inception, serta strategi fine-tuning yang diaplikasikan pada domain yang berbeda. Keunggulan penelitian ini terletak pada cakupan teoritisnya yang luas dan sistematis, yang dapat menjadi fondasi kuat bagi penelitian lanjutan. Meskipun demikian, studi ini belum menyertakan eksperimen empiris secara langsung, sehingga masih terbuka ruang untuk validasi melalui studi kasus nyata.

2.5.2 “Penelitian oleh Li et al”

Penelitian berjudul “Using Convolutional Neural Network for Defective Image Classification of Industrial Components”, Li dan tim mengembangkan sistem klasifikasi citra berbasis CNN untuk mendeteksi cacat pada komponen industri. Dengan menggunakan PyTorch sebagai kerangka kerja, penelitian ini memperlihatkan efektivitas CNN dalam mengenali pola cacat meski terdapat gangguan seperti variasi pencahayaan dan tekstur permukaan.

Arsitektur CNN yang digunakan cukup sederhana namun diperkuat dengan regularisasi dropout guna mencegah overfitting. Data pelatihan diperoleh dari proses pelabelan manual, yang memastikan kualitas data. Hasil eksperimen menunjukkan akurasi melebihi 91%, namun penelitian ini masih terbatas pada jenis cacat yang telah dikenali, sehingga kemampuan generalisasi terhadap jenis cacat baru belum sepenuhnya teruji.

2.5.3 "Penelitian oleh Ahmed dan Kumar"

Penelitian berjudul “Defect Analysis of 3D Printed Cylinder Object Using Transfer Learning Approaches” mengevaluasi efektivitas beberapa arsitektur pretrained seperti VGG16, ResNet50, dan InceptionResNetV2 dalam mendeteksi cacat pada objek silinder hasil cetak 3D. Objek silinder dipilih karena memiliki kontur geometris yang menantang dan sering menjadi kendala dalam sistem inspeksi otomatis.

Model-model tersebut diuji dengan strategi fine-tuning pada dataset spesifik untuk domain manufaktur aditif. Hasilnya menunjukkan bahwa MobileNetV2 memberikan performa terbaik dalam mendeteksi cacat. Studi ini menunjukkan bahwa transfer learning merupakan pendekatan yang menjanjikan untuk sistem inspeksi berbasis citra dalam industri cetak 3D. Namun, cakupan penelitian masih terbatas pada satu jenis objek, sehingga eksplorasi lebih lanjut diperlukan untuk memperluas aplikasi ke objek dengan morfologi yang berbeda.

2.5.4 " Penelitian oleh Zhang et al"

Dalam studi “Smart Defect Detection in Aero-Engines: Evaluating Transfer Learning with VGG19 and Data-Efficient Image Transformer Models”, Zhang dan kolega membandingkan performa dua pendekatan deep learning—VGG19 dan Data-Efficient Image Transformer (DeiT)—dalam mengklasifikasi kerusakan komponen aero-engine.

Eksperimen dilakukan pada citra kerusakan mesin dengan anotasi dari pakar. Hasilnya menunjukkan bahwa model berbasis CNN seperti VGG19 memiliki akurasi dan presisi yang lebih unggul dibanding transformer DeiT, khususnya dalam kondisi data terbatas. Penelitian ini menegaskan bahwa

CNN tetap menjadi pendekatan yang andal dalam domain inspeksi industri, meskipun teknologi Vision Transformer kian berkembang.

2.5.5 “Penelitian oleh Singh dan Patel”

Studi berjudul “Automated Defect Identification System in Printed Circuit Boards Using Region-Based Convolutional Neural Networks” merancang sistem deteksi cacat otomatis pada papan sirkuit cetak (PCB) dengan menggunakan Faster R-CNN yang terintegrasi dengan ResNet-50 sebagai backbone. Sistem ini juga dilengkapi dengan antarmuka pengguna grafis (GUI) untuk mendukung penerapan dalam lingkungan industri.

Jenis cacat yang berhasil dideteksi meliputi missing pads, solder bridge, dan open circuit. Model mencatatkan akurasi sebesar 87% dengan waktu inferensi yang kompetitif. Salah satu kekuatan penelitian ini adalah integrasi antara teknologi deteksi real-time dengan antarmuka pengguna yang intuitif. Namun, pemilihan arsitektur backbone menjadi faktor kritical karena model seperti Inception dan ConvNeXt menunjukkan performa suboptimal.

2.5.6 “Penelitian oleh Wang et al”

Penelitian “Fabric Defect Detection Method Using SA-Pix2pix Network and Transfer Learning” mengusulkan metode deteksi cacat pada kain dengan pola kompleks menggunakan kombinasi transfer learning dan arsitektur generatif SA-Pix2pix yang dilengkapi mekanisme self-attention.

Model ini mampu merekonstruksi citra normal dan membedakan bagian yang tidak sesuai sebagai cacat. Penerapan pada dataset dengan pola non-periodik menunjukkan peningkatan akurasi signifikan dibanding metode tradisional. Kompleksitas arsitektur menjadi tantangan utama untuk

implementasi di industri, namun pendekatan ini membuka peluang baru dalam inspeksi kualitas berbasis citra.

2.5.7 “Penelitian oleh Rahman dan Choi”

TransferD2, sebagaimana diperkenalkan dalam studi berjudul “TransferD2: Automated Defect Detection Approach in Smart Manufacturing using Transfer Learning Techniques”, merupakan kerangka kerja deteksi cacat otomatis yang mengandalkan model pralatih seperti Xception dan ResNet101V2.

Dengan memanfaatkan teknik fine-tuning dan augmentasi data secara intensif, model mencapai akurasi hingga 95,72% meski data pelatihan terbatas. Studi ini memperlihatkan efektivitas pendekatan transfer learning dalam skenario manufaktur cerdas. Namun, belum ada uji validasi terhadap implementasi pada sistem real-time skala besar, yang menjadi area pengembangan selanjutnya.

2.5.8 “Penelitian oleh Tan dan Le”

Dalam penelitian berjudul “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks”, Tan dan Le mengkaji efektivitas EfficientNet dalam klasifikasi bentuk cacat menggunakan pendekatan inspeksi nondestruktif berbasis magneto-optik. Model ini mengadopsi strategi compound scaling untuk mengoptimalkan performa dalam skala parameter yang seimbang.

Penelitian menunjukkan bahwa dengan transfer learning, EfficientNet mampu menghasilkan akurasi tinggi meski dataset yang digunakan relatif kecil. Studi ini relevan untuk domain teknik visual kompleks dan memperkuat pentingnya efisiensi model dalam konteks industri.

2.5.9 “Penelitian oleh Yoon et al”

Penelitian berjudul "Deep Transfer Learning-Based Fault Diagnosis Using Wavelet Transform for Limited Data" oleh Yoon dan rekan, meneliti metode diagnosis kesalahan mesin industri di Korea Selatan dengan memanfaatkan integrasi antara transfer learning dan transformasi wavelet. Dalam penelitian ini, fitur dari sinyal getaran diekstrak menggunakan wavelet transform, kemudian dimasukkan ke dalam model CNN yang telah dilatih sebelumnya melalui strategi transfer learning.

Hasil eksperimen menunjukkan bahwa pendekatan kombinasi ini memberikan akurasi klasifikasi yang lebih tinggi dibandingkan CNN konvensional tanpa fitur wavelet. Penelitian ini menyoroti potensi teknik ini untuk diterapkan dalam sistem diagnosis peralatan teknik, meskipun cakupannya masih terbatas pada jenis mesin tertentu.

2.5.10 “Penelitian oleh Zhao dan Li”

Penelitian berjudul "A Wavelet Transform and Self-Supervised Learning-Based Framework for Bearing Fault Diagnosis with Limited Labeled Data" oleh Zhao dan Li, mengembangkan kerangka kerja diagnosis kesalahan pada bantalan mesin dengan menggabungkan transformasi wavelet dan pembelajaran mandiri. Sinyal getaran diubah menjadi representasi waktu-frekuensi, kemudian diproses menggunakan arsitektur Vision Transformer (ViT).

Dengan hanya memanfaatkan 1% data berlabel, model berhasil mencapai akurasi lebih dari 90%, membuktikan efisiensi pendekatan pembelajaran semi-terawasi. Walau demikian, tantangan implementasi

muncul dari kompleksitas arsitektur yang memerlukan perangkat keras berkemampuan tinggi untuk pengolahan secara real-time.

2.5.11 "Penelitian oleh Chen dan Wang"

Dalam penelitian "A Hybrid Deep Learning Approach for Bearing Fault Diagnosis Using Continuous Wavelet Transform and Attention-Enhanced Spatiotemporal Feature Extraction", Chen dan Wang merancang sistem diagnosis kesalahan bantalan yang mengintegrasikan Continuous Wavelet Transform (CWT), CNN residual, dan mekanisme attention. Data getaran diubah menjadi fitur spasio-temporal yang kemudian dianalisis melalui jaringan dalam.

Eksperimen yang dilakukan menunjukkan akurasi mendekati 100%, menandakan efektivitas pendekatan hybrid dalam klasifikasi kesalahan secara presisi tinggi. Kendati begitu, arsitektur yang kompleks masih menjadi kendala implementasi langsung di lingkungan industry.

2.5.12 " Penelitian oleh Xu et al"

Studi "Exploring Wavelet Transformations for Deep Learning-Based Machine Diagnosis" yang dilakukan oleh Xu dan tim mengevaluasi bagaimana transformasi wavelet dapat meningkatkan diagnosis mesin berbasis deep learning. Transformasi sinyal motor listrik menjadi representasi citra dilakukan dengan metode Wavelet Synchrosqueezed Transform (WSST) dan selanjutnya diproses menggunakan CNN.

Model menunjukkan akurasi mencapai 93,73% dalam mendeteksi kondisi operasional mesin, membuktikan keunggulan pembelajaran spasio-temporal terhadap sinyal yang dikonversi. Meski menjanjikan, performa

WSST masih perlu disempurnakan karena sensitivitas rendah terhadap beberapa jenis dataset.

2.5.13 "Penelitian oleh Liu dan Zhang"

Penelitian berjudul "Deep Transfer Multi-Wavelet Auto-Encoder for Gearbox Fault Diagnosis" oleh Liu dan Zhang menawarkan pendekatan diagnosis kesalahan pada gearbox dengan memanfaatkan auto-encoder berbasis multi-wavelet serta transfer learning. Model dilatih terlebih dahulu pada data sumber, kemudian diterapkan pada domain target dengan fine-tuning minimal.

Studi ini menunjukkan bahwa meskipun data pelatihan target sangat terbatas, model tetap dapat mengidentifikasi kesalahan gearbox secara akurat. Hasil ini mendukung efektivitas strategi transfer learning untuk skenario industri yang memiliki keterbatasan data.

2.5.14 "Penelitian oleh Huang dan Feng"

Dalam studi "Fault Diagnosis for Power Electronics Converters Based on Deep Feedforward And Wavelet", Huang dan Feng merancang sistem diagnosis untuk konverter elektronik daya dengan menggabungkan kompresi sinyal wavelet dan jaringan deep feedforward. Metode ini diuji pada berbagai kondisi kegagalan konverter.

Eksperimen menunjukkan akurasi melebihi 97% serta waktu pelatihan yang relatif singkat, yang menegaskan efisiensi pendekatan ini untuk aplikasi industri real-time. Namun, keterbatasannya adalah fokus penelitian masih terbatas pada tipe konverter tertentu saja.

2.5.15 “Penelitian oleh Zhang dan Liu”

Penelitian berjudul “*Fault Diagnosis for Power Electronics Converters Based on Deep Feedforward And Wavelet*” yang dilakukan oleh Zhang dan Liu bertujuan untuk mengembangkan sebuah sistem diagnosis kerusakan pada konverter elektronik daya melalui integrasi antara metode kompresi wavelet dan jaringan deep feedforward neural network. Fokus utama studi ini adalah meningkatkan kecepatan dan akurasi dalam mendeteksi anomali operasional pada perangkat konversi daya, yang memiliki peran vital dalam sistem kelistrikan industri.

Dalam pendekatannya, transformasi wavelet digunakan sebagai tahap awal untuk mereduksi dimensi sinyal serta mengekstraksi fitur dominan dari data masukan, yang kemudian diteruskan ke dalam arsitektur deep feedforward untuk klasifikasi kerusakan. Hasil uji coba empiris menunjukkan bahwa model yang dikembangkan mampu mencapai tingkat akurasi melebihi 97% dengan waktu pelatihan yang relatif efisien, menjadikannya sangat kompetitif untuk diterapkan dalam sistem monitoring real-time di lingkungan industri.

Meskipun demikian, lingkup eksperimen masih terbatas pada tipe konverter tertentu, yang dapat memengaruhi generalisasi model jika dihadapkan pada variasi perangkat keras yang lebih kompleks. Oleh karena itu, meskipun pendekatan ini menunjukkan potensi besar dalam sistem diagnosis berbasis citra dan sinyal, diperlukan pengujian lebih lanjut pada berbagai jenis perangkat konversi untuk memastikan robusta performa sistem di berbagai skenario industri nyata.

BAB III

METODOLOGI PENELITIAN

3.1 Tinjauan Umum Perusahaan

PT XYZ adalah perusahaan yang bergerak di bidang percetakan, khususnya dalam produksi kemasan. Perusahaan ini didirikan pada tahun 2005 dan berlokasi di Kawasan Industri Benua Permai Lestari, Desa Cisereh, Kecamatan Tigaraksa, Kabupaten Tangerang, Banten. Sejak awal berdiri, PT XYZ telah fokus pada penyediaan kemasan berkualitas tinggi untuk berbagai sektor, termasuk industri makanan, minuman, kosmetik, dan produk konsumen lainnya.

Dengan pengalaman lebih dari 15 tahun, perusahaan ini telah berkembang pesat, menggabungkan teknologi percetakan modern dan bahan baku berkualitas untuk menghasilkan produk kemasan yang tidak hanya fungsional tetapi juga menarik secara visual. PT XYZ memanfaatkan mesin dan peralatan canggih dalam proses produksi untuk memastikan setiap produk memenuhi standar kualitas tinggi dan dapat diandalkan oleh pelanggan.


Perusahaan ini juga dikenal dengan komitmennya terhadap keberlanjutan lingkungan, dengan menggunakan bahan baku ramah lingkungan dan menerapkan proses produksi yang efisien dan bertanggung jawab. Selain itu, PT XYZ selalu mengutamakan inovasi dalam desain dan fungsi kemasan, yang sesuai dengan tren pasar dan kebutuhan industri.

Hingga saat ini, PT XYZ terus berkembang dengan menjalin kerjasama dengan berbagai perusahaan besar di Indonesia, serta memperluas jangkauan pasar untuk memenuhi permintaan kemasan di pasar domestik maupun internasional. Dengan tim yang berkompeten dan dedikasi terhadap kualitas, PT

Satya Mitra Kemas Lestari terus berkomitmen untuk memberikan solusi kemasan terbaik bagi para pelanggannya.

3.1.1 Struktur Organisasi

Struktur Organisasi PT.XYZ dirancang secara fungsional, dengan pembagian kerja yang mendukung efisiensi tim dalam menjalankan proyek proyek berkelanjutan. Berikut adalah struktur organisasi PT.XYZ



Gambar 3. 1 Struktur Organisasi PT Satya Mitra Kemas lestari.TBK

3.1.1.1 Tugas dan Wewenang

Dalam setiap struktur organisasi pasti akan ada tugas dan wewenang untuk mendukung efisiensi dalam menjalankan tugas serta proyek. Berikut adalah penjelasan tugas dan wewenang dari setiap bagian orgnasasi :

1. CEO

- Tugas:
 - Memimpin dan mengendalikan seluruh kegiatan perusahaan.
 - Menetapkan visi, misi, dan kebijakan strategis.

- Wewenang:
 - Menetapkan keputusan strategis final.
 - Menyetujui kebijakan jangka panjang perusahaan.

2. COO

- Tugas:
 - Menjalankan dan mengawasi seluruh kegiatan operasional.
 - Menerjemahkan kebijakan strategis menjadi operasional.
- Wewenang:
 - Menyetujui program kerja tahunan operasional.
 - Mengarahkan aktivitas direktorat di bawahnya.

3. GM MIS

- Tugas:
 - Mengelola sistem informasi perusahaan.
- Wewenang:
 - Menetapkan pengembangan sistem IT.

4. Manager EDP

- Tugas:
 - Mengembangkan dan mengoperasikan sistem informasi.

3.2 Prosedur Sistem

Sistem yang dirancang ini merupakan solusi berbasis pembelajaran mesin untuk mendeteksi kondisi toner printer. Sistem memanfaatkan teknologi terkini seperti *Convolutional Neural Network* (CNN) untuk menganalisis citra

secara visual. Dengan pendekatan ini, pengguna dapat mengidentifikasi tiga kondisi utama toner—bocor, habis, atau normal—tanpa memerlukan pemeriksaan manual yang memakan waktu. Prosedur sistem ini dirancang agar efisien, akurat, dan mudah diakses oleh berbagai kalangan.

3.2.1 Tujuan Sistem

Sistem ini dirancang untuk mendeteksi kondisi toner printer menggunakan analisis citra berbasis pembelajaran mesin. Tiga kategori yang dapat diidentifikasi oleh sistem adalah:

- a. Bocor: Citra menunjukkan pola kerusakan seperti goresan, bercak tinta berlebihan, atau garis terputus. Kondisi ini biasanya terjadi karena kerusakan mekanis atau toner yang tidak tertutup rapat. Deteksi dini dapat menghindarkan pengguna dari hasil cetakan yang tidak memuaskan.
- b. Habis: Toner yang tidak memiliki cukup tinta untuk mencetak dokumen dengan jelas sering kali menghasilkan hasil cetakan yang pudar atau tidak konsisten. Kategori ini dirancang untuk memastikan pengguna mengganti toner sebelum proses pencetakan terganggu.
- c. Normal: Toner berada dalam kondisi optimal dengan kapasitas tinta yang cukup. Hasil cetakan yang dihasilkan tajam dan seragam, tanpa adanya pola kerusakan yang mencolok.

Sistem ini dirancang untuk mempermudah proses pemeliharaan printer. Dengan mengurangi kebutuhan pemeriksaan manual, pengguna dapat menghemat waktu dan meningkatkan produktivitas.

3.2.2 Tahapan Proses Deteksi

a. Pengumpulan Data Gambar

Sistem memerlukan citra toner printer sebagai input utama. Data ini dapat diperoleh melalui beberapa metode:

1. Pengunggahan File: Pengguna dapat mengunggah gambar toner dalam format umum seperti ".jpg" atau ".png" melalui antarmuka sistem. Fitur ini memungkinkan sistem untuk menerima input dari berbagai perangkat, termasuk kamera ponsel.
2. Pemotretan Langsung: Selain unggah file, pengguna juga dapat menggunakan webcam untuk menangkap gambar toner secara langsung. Metode ini sangat berguna untuk pengguna yang ingin proses deteksi berjalan lebih cepat dan praktis.

Input gambar yang diterima sistem akan langsung diproses untuk memastikan kualitasnya memadai sebelum dianalisis lebih lanjut.

b. *Preprocessing* Gambar


Preprocessing gambar adalah langkah penting dalam memastikan data siap dianalisis oleh model. Proses ini mencakup beberapa tahap berikut:

1. **Resize Gambar**

Semua gambar diubah ukurannya menjadi 128×128 piksel. Langkah ini tidak hanya menyelaraskan dimensi input dengan kebutuhan model CNN, tetapi juga mengurangi beban komputasi tanpa mengorbankan kualitas informasi visual yang penting.

2. *Sharpening* (Penajaman Gambar)

- Proses penajaman dilakukan menggunakan kernel konvolusi berikut:



```
[ 0, -1, 0]
[-1,  5, -1]
[ 0, -1, 0]
```

Gambar 3. 2 Contoh Proses *Sharpening*

Proses penajaman menggunakan kernel konvolusi dirancang untuk memperjelas detail gambar, seperti tepi garis atau pola bercak tinta. Penajaman ini membantu model mengenali pola kerusakan dengan lebih akurat.

3. Normalisasi Piksel

Nilai piksel gambar dinormalisasi ke rentang 0-1 dengan membagi setiap nilai piksel dengan 255. Hal ini meningkatkan stabilitas dan efisiensi pelatihan model.

Langkah-langkah ini memastikan bahwa gambar yang dianalisis memiliki kualitas optimal dan representasi visual yang konsisten.

c. Model CNN Untuk Klasifikasi

Model CNN digunakan untuk mengidentifikasi pola visual dan mengklasifikasikan gambar toner. Berikut adalah rincian setiap lapisan dalam arsitektur model:

1. Layer Konvolusi dan Pooling

Lapisan ini mengekstraksi fitur penting seperti garis, tekstur, dan pola lainnya dari gambar. Pooling layer membantu mereduksi dimensi data, membuat proses analisis lebih efisien tanpa kehilangan fitur yang signifikan.

2. Flatten Layer

Output dari layer konvolusi diubah menjadi format satu dimensi. Proses ini memungkinkan data untuk diteruskan ke lapisan dense, yang bertanggung jawab dalam pengambilan keputusan.

3. Dense dan Dropout Layer

Dense layer mengolah informasi dari layer sebelumnya untuk menentukan kategori toner. Dropout layer diterapkan untuk mengurangi risiko *overfitting*, sehingga model mampu memberikan prediksi yang lebih akurat..

4. Softmax Output Layer

Lapisan ini mengubah output menjadi probabilitas antar kategori ('Bocor', 'Habis', 'Normal'), memungkinkan sistem memilih hasil dengan kepercayaan tertinggi.

d. Deteksi Garis Putus atau Teks Pudar

Sebagai pelengkap CNN, sistem juga menggunakan teknik *edge detection* untuk mendeteksi kerusakan fisik pada toner, seperti garis putus atau teks yang pudar. Prosesnya meliputi:

1. Konversi ke *Grayscale*

Gambar berwarna diubah menjadi grayscale untuk menyederhanakan analisis tepi.

2. *Canny Edge Detection*

Metode ini mendeteksi tepi dengan membandingkan intensitas piksel di area sekitarnya. Outputnya adalah gambar biner dengan tepi berwarna putih dan area lainnya hitam.

3. Penghitungan *Edge Density*

Sistem menghitung kepadatan tepi sebagai indikator tingkat kerusakan:

Jika *edge density* rendah ($< 5\%$), toner diklasifikasikan sebagai 'Bocor' karena kemungkinan adanya garis putus atau pudar.

e. **Prediksi dan Interpretasi Akhir**

Setelah preprocessing dan analisis model selesai, sistem memberikan output berupa:

1. Label Kategori: 'Bocor', 'Habis', atau 'Normal'.
2. *Confidence Score*: Persentase kepercayaan model terhadap prediksi yang dihasilkan.

Jika deteksi tepi menunjukkan kerusakan signifikan, hasil prediksi akan dikoreksi untuk memastikan toner diklasifikasikan sebagai 'Bocor'.

3.2.3 **Keunggulan Sistem**

1. Kombinasi Teknik Modern

Kombinasi CNN dan edge detection memberikan solusi yang komprehensif untuk mendeteksi berbagai masalah toner, dari kerusakan fisik hingga pola tinta yang tidak normal.

2. Data Augmentation

Dengan augmentasi data seperti rotasi dan flipping, sistem mampu mengenali berbagai kondisi toner dengan lebih baik, termasuk variasi pola kerusakan yang jarang terjadi.

3. Akurasi Tinggi

Model dilengkapi dengan validasi tambahan melalui analisis tepi untuk memastikan prediksi 'Bocor' lebih akurat.

4. Fleksibilitas Input

Sistem mendukung pengunggahan file dan penggunaan webcam, memudahkan berbagai jenis pengguna.

3.3 Metode Pendekatan

Penelitian ini menggunakan dua metode utama untuk mencapai tujuan klasifikasi, yaitu *transfer learning* dan *Convolutional Neural Network (CNN)*.

3.3.1 Eksperimen (*Quantitative Experimental*)

Metode eksperimen kuantitatif merupakan pendekatan yang digunakan untuk mengukur dan membandingkan hasil kinerja model CNN secara sistematis berdasarkan angka dan statistik. Dalam penelitian ini, metode ini digunakan untuk mengevaluasi kemampuan model dalam mengklasifikasikan citra hasil cetakan printer laser ke dalam kategori *bocor*, *habis*, atau *normal*. Evaluasi dilakukan menggunakan data uji dan validasi yang disiapkan terpisah dari data pelatihan untuk menghindari bias dan mengukur generalisasi model terhadap data baru.

Model dievaluasi dengan menggunakan sejumlah metrik pengukuran performa klasifikasi, antara lain: akurasi, presisi, *recall*, dan *F1-score*. Metrik-metrik ini memberikan wawasan berbeda terhadap efektivitas model. Misalnya, presisi menunjukkan seberapa banyak prediksi positif benar dari total yang diprediksi, sedangkan *recall* mengukur seberapa banyak kasus positif yang berhasil dikenali model dari seluruh kasus aktual. *F1-score* sendiri adalah harmonisasi dari kedua metrik tersebut. Formula dasar yang digunakan antara lain:

- $ACCURACY = \frac{(TP+TN)}{(TP+TN+FP+FN)}$
- $Precision = \frac{TP}{TP+FP}$
- $Recall = \frac{TP}{TP+FN}$
- $F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall}$

Pentingnya pendekatan kuantitatif terletak pada kemampuan mengonversi performa sistem ke dalam angka konkret yang dapat dibandingkan secara objektif antar model dan antar konfigurasi pelatihan. Dalam konteks sistem yang digunakan oleh PT XYZ, nilai akurasi tinggi (>90%) sangat penting karena keputusan sistem berdampak langsung pada keandalan hasil cetakan produk yang dikirimkan ke pelanggan.

Model CNN yang digunakan akan menjalani proses pelatihan selama beberapa epoch, dan performanya pada tiap epoch dapat dipantau melalui visualisasi kurva *loss* dan *accuracy*. Kurva ini memberikan pemahaman tentang dinamika pelatihan model,

seperti potensi overfitting (ketika akurasi pelatihan jauh lebih tinggi daripada akurasi validasi). Evaluasi akhir dilakukan dengan melihat *confusion matrix* yang menunjukkan jumlah prediksi benar dan salah pada masing-masing kelas(L. Chen et al., 2021).

3.3.2 Pengembangan Sistem (Prototyping)

Pendekatan *prototyping* merupakan strategi pengembangan perangkat lunak yang memungkinkan sistem dibangun secara bertahap. Dalam penelitian ini, *prototyping* digunakan untuk membangun sistem klasifikasi kualitas cetakan printer secara modular: dimulai dari antarmuka pengguna (untuk unggah gambar), dilanjutkan dengan modul *preprocessing* (resize, normalisasi), dan diakhiri dengan prediksi menggunakan CNN. Prototipe awal dikembangkan dengan fokus pada alur minimal yang fungsional, lalu ditingkatkan berdasarkan evaluasi dan umpan balik pengguna atau evaluator.

Pendekatan ini sejalan dengan praktik dalam pengembangan antarmuka pengguna berbasis AI, di mana *prototyping* modular memungkinkan integrasi komponen seperti *upload handler*, *model loader*, dan analisis hasil klasifikasi secara bertahap. Studi oleh (Reiss Harris, 2020) memperkenalkan *PrototypeML*, sebuah lingkungan pengembangan yang mendukung desain visual jaringan saraf, yang mempercepat proses pengembangan dan debugging model pembelajaran mendalam.

Keuntungan dari pendekatan ini adalah memungkinkan pengujian sistem secara cepat pada tahap-tahap awal

pengembangan, sehingga koreksi dapat dilakukan sedini mungkin. Dengan cara ini, risiko kesalahan sistem di tahap akhir bisa diminimalkan. Setiap iterasi prototipe mencerminkan perbaikan dari versi sebelumnya, baik dari segi desain antarmuka, kecepatan sistem, maupun akurasi model.

Pendekatan *prototyping* juga mendukung pengembangan sistem yang berorientasi pada pengguna (*user-centered design*). (Kolthoff et al., 2025) mengembangkan *GUIDE*, sebuah pendekatan berbasis *Large Language Models* (LLMs) untuk otomatisasi *prototyping* antarmuka pengguna, yang memungkinkan adaptasi cepat terhadap kebutuhan pengguna melalui integrasi dengan kerangka kerja seperti Figma.

Dalam penelitian ini, *prototyping* mendukung pendekatan eksperimental karena proses evaluasi dilakukan terhadap prototipe yang sedang dikembangkan, bukan sekadar simulasi. Komponen sistem seperti *upload handler*, *model loader*, dan analisis hasil klasifikasi diuji dalam kondisi nyata melalui aplikasi berbasis Flask yang terhubung langsung ke model CNN.

Pendekatan ini konsisten dengan praktik dalam pengembangan sistem pembelajaran mendalam untuk tugas-tugas klasifikasi kualitas. (Wang & Zhang, n.d.) menunjukkan bahwa evaluasi kualitas antarmuka pengguna menggunakan CNN dapat mencapai korelasi tinggi dengan penilaian pengguna, menekankan pentingnya integrasi umpan balik pengguna dalam proses pengembangan.

Prototyping juga mendorong partisipasi pengguna langsung dalam proses pengembangan sistem. Misalnya, teknisi QC di PT XYZ dilibatkan untuk menguji sistem dan memberikan umpan balik terhadap hasil klasifikasi yang muncul. Hal ini sejalan dengan prinsip *user-centered design*, di mana pengembangan diarahkan untuk memenuhi kebutuhan aktual pengguna akhir.

Pendekatan ini diperkuat oleh studi (Efendi et al., 2021), yang menekankan pentingnya keterlibatan pengguna dalam perancangan ulang antarmuka sistem informasi sekolah menggunakan metode *user-centered design*, yang menghasilkan peningkatan signifikan dalam kepuasan pengguna.

3.3.3 *Convolutional Neural Network (CNN)*

Transfer learning adalah metode pembelajaran mesin yang memungkinkan model memanfaatkan bobot hasil pelatihan dari dataset besar seperti *ImageNet* ke dalam tugas klasifikasi baru. Dalam proyek ini, model *pretrained* seperti *ResNet50* dan *VGG16* digunakan sebagai feature extractor untuk klasifikasi hasil cetakan printer. Layer awal model dibiarkan dalam keadaan *pretrained*, sementara layer akhir (*fully connected layer*) dilatih ulang (*fine-tuning*) untuk mengenali kategori cetakan seperti ‘bocor’, ‘habis’, dan ‘normal’. Pendekatan ini sangat efisien karena mempersingkat waktu pelatihan secara signifikan.

Tanpa *transfer learning*, pelatihan model dari awal (*training from scratch*) akan membutuhkan waktu yang jauh lebih lama, serta data dalam jumlah besar agar model dapat belajar secara efektif.

Transfer learning memanfaatkan pengetahuan sebelumnya, misalnya deteksi pola, tekstur, atau garis, yang telah dipelajari model dari ratusan ribu gambar di ImageNet.

Keunggulan lain dari pendekatan ini adalah akurasi tinggi pada dataset kecil. Karena model telah “belajar” fitur dasar dari dataset besar, hanya sedikit penyesuaian yang dibutuhkan untuk mengadaptasinya ke domain spesifik seperti hasil cetakan printer.

Hal ini sangat bermanfaat dalam industri manufaktur, di mana data khusus bersifat terbatas dan mahal untuk dikumpulkan secara massal. Transfer learning juga mendukung interoperabilitas antar perangkat keras. Model yang telah dilatih dalam lingkungan berbasis *cloud* seperti *Google Colab* dapat dengan mudah dipindahkan ke sistem lokal atau server PT XYZ untuk kebutuhan deployment. Proses fine-tuning biasanya menggunakan optimizer seperti Adam dan fungsi aktivasi *ReLU* di layer konvolusional, serta Softmax untuk klasifikasi akhir (Haque et al., 2024).

3.4 Alat dan Platform

3.4.1 Perangkat Keras (*Hardware*)

Dalam penelitian ini, pemilihan perangkat keras menjadi aspek krusial karena kompleksitas arsitektur *Convolutional Neural Network* (CNN) yang melibatkan ribuan hingga jutaan parameter serta operasi komputasi intensif seperti konvolusi, aktivasi, dan propagasi balik. Oleh karena itu, sistem pelatihan model dilaksanakan menggunakan *Graphics Processing Unit* (GPU) untuk mempercepat proses komputasi yang bersifat paralel. Adapun pelatihan utama dilakukan pada GPU kelas server

NVIDIA Tesla K80 yang dikenal memiliki arsitektur *CUDA* yang mendukung komputasi paralel masif, sehingga sangat cocok untuk pelatihan model deep learning dalam skala menengah hingga besar.

Efektivitas penggunaan GPU ini diperkuat oleh studi Yang et al. (2021), yang menyatakan bahwa akselerasi GPU mampu mempercepat pelatihan model deep learning sebesar 5–10 kali lipat dibandingkan dengan penggunaan CPU konvensional dalam eksperimen pelatihan CNN berbasis citra. Hal ini menjadikan GPU sebagai komponen wajib dalam eksperimen pembelajaran mesin modern, terutama untuk klasifikasi visual berbasis data besar.

Untuk keperluan pengembangan lokal dan debugging ringan, penelitian ini juga menggunakan laptop pribadi Acer Nitro dengan spesifikasi prosesor *AMD Ryzen 5 5600H*, GPU *NVIDIA GTX 1650*, serta *RAM 16 GB*. Konfigurasi tersebut terbukti cukup andal dalam menjalankan proses *image preprocessing*, pelatihan model sederhana, serta pengujian web berbasis *Flask* secara simultan tanpa hambatan performa berarti. Sistem ini juga mendukung *TensorFlow GPU* melalui *CUDA Toolkit*, sehingga memungkinkan replikasi sebagian besar eksperimen secara lokal sebelum deployment pada cloud atau server.

3.4.2 Perangkat Lunak (*Software*)

- a. **Python:** Bahasa pemrograman *Python* digunakan untuk mengembangkan dan melatih model CNN. Python merupakan bahasa yang paling banyak digunakan dalam penelitian *deep learning* karena pustaka-pustakanya yang kuat dalam pengolahan gambar dan pelatihan model.

- b. **TensorFlow/Keras:** *TensorFlow* adalah pustaka open-source untuk komputasi numerik yang mendukung machine learning dan deep learning, sementara Keras adalah API tingkat tinggi yang memudahkan pembuatan dan pelatihan model *deep learning*. Keras digunakan dalam penelitian ini untuk membangun dan melatih model CNN, serta menerapkan *transfer learning*.
- c. **OpenCV:** OpenCV digunakan untuk pemrosesan citra, seperti *resize*, *cropping*, dan augmentasi data. Teknik augmentasi data seperti rotasi, *flipping*, dan perubahan pencahayaan diterapkan untuk meningkatkan variasi data dan menghindari *overfitting* pada model.

3.4.3 Visual Studi Code

Platform pengembangan utama yang digunakan dalam penelitian ini adalah *Visual Studio Code (VS Code)*, sebuah *Integrated Development Environment (IDE)* yang ringan namun sangat fungsional. VS Code dipilih karena mendukung berbagai ekstensi penting seperti *Python*, *Jupyter Notebook*, *TensorFlow Tools*, serta *Git*, yang memungkinkan peneliti bekerja secara efisien dalam satu ekosistem pengembangan yang terintegrasi.

Beberapa keunggulan dari VS Code meliputi fitur *customizable interface* yang dapat disesuaikan dengan preferensi pengguna; terminal terintegrasi yang memudahkan eksekusi skrip *Python*, *pip*, serta perintah *git* tanpa keluar dari editor; serta fitur *linting* dan *IntelliSense* yang menyediakan koreksi otomatis, saran sintaksis, dan analisis kode secara real-time. Dengan fitur-fitur ini, pengembangan dan debugging model

dapat dilakukan dengan lebih cepat, akurat, dan bebas dari kesalahan sintaksis minor.

Selain itu, kemampuan integrasi dengan environment virtual seperti *Anaconda*, *venv*, dan *Docker* memungkinkan peneliti menjaga kestabilan dependensi dan versi pustaka secara terpisah antara satu proyek dan lainnya. Hal ini penting dalam konteks reproduktifitas hasil eksperimen dan memudahkan deployment model ke lingkungan cloud atau *edge device* di kemudian hari.

3.5 Pengumpulan Data

Pengumpulan data merupakan salah satu tahapan paling krusial dalam penelitian ini, mengingat keberhasilan model *Convolutional Neural Network* (CNN) sangat bergantung pada kualitas, keragaman, dan representativitas data yang digunakan dalam proses pelatihan. Data yang dikumpulkan harus mencerminkan berbagai kondisi nyata dari hasil cetakan printer laser yang mengalami gangguan berupa kebocoran tinta, untuk memastikan bahwa model memiliki kemampuan generalisasi yang baik. Oleh karena itu, metode pengumpulan data dirancang secara sistematis untuk mencakup seluruh kemungkinan variasi visual dari cacat cetak yang mungkin terjadi.

Data yang digunakan dalam penelitian ini dikumpulkan melalui pendekatan observasi langsung terhadap hasil cetakan dari berbagai unit printer laser. Pengamatan dilakukan pada cetakan yang menunjukkan adanya gangguan visual seperti noda tinta, garis tidak beraturan, serta degradasi kualitas teks atau gambar. Citra-citra hasil cetak ini kemudian diolah lebih lanjut dan diklasifikasikan sesuai dengan kategori performa cetaknya.

Seluruh proses ini bertujuan untuk menyediakan dataset yang akurat dan dapat digunakan sebagai fondasi dalam pelatihan model CNN.

Selain itu, proses pelabelan data dilakukan secara manual dengan melibatkan observasi visual oleh beberapa evaluator untuk memastikan validitas data. Setiap citra dikategorikan secara biner, yakni sebagai "baik" apabila hasil cetakan tidak menunjukkan gejala kebocoran tinta, dan sebagai "buruk" apabila terdapat indikasi visual kebocoran tinta. Validasi silang antar evaluator juga dilakukan guna meningkatkan konsistensi dan objektivitas dalam pelabelan data.

Langkah-langkah dalam proses pengumpulan data ini tidak hanya penting untuk membentuk dataset yang representatif, namun juga menentukan kemampuan model dalam mendeteksi pola-pola cacat pada hasil cetak dengan presisi tinggi. Oleh karena itu, setiap tahapan dalam proses pengumpulan data didesain untuk meminimalkan potensi bias serta meningkatkan relevansi dataset terhadap kondisi nyata di lapangan. Proses pengumpulan data dilakukan melalui langkah-langkah berikut:

a. **Pemilihan Printer**

Dalam upaya menciptakan dataset yang beragam dan representatif, tahap awal yang dilakukan adalah pemilihan jenis printer laser yang akan digunakan sebagai sumber data. Pemilihan printer tidak dilakukan secara acak, melainkan dengan mempertimbangkan keragaman merek, model, dan teknologi yang digunakan oleh printer tersebut. Hal ini penting karena masing-masing printer memiliki karakteristik internal yang berbeda dalam proses pencetakan, sehingga menghasilkan pola kebocoran tinta yang bervariasi.

Beberapa merek printer laser terkemuka seperti *Hewlett-Packard* (HP), Canon, dan Brother dipilih untuk memastikan cakupan variasi yang luas. Merek-merek ini memiliki pangsa pasar yang besar dan digunakan secara luas baik di lingkungan perkantoran maupun rumah tangga. Dengan menggunakan berbagai model dari merek yang berbeda, penelitian ini memperoleh cakupan data yang lebih luas dan realistis, yang pada gilirannya membantu model CNN untuk belajar mengenali pola kebocoran tinta dari berbagai sumber.

Perbedaan dalam struktur internal printer, mulai dari mekanisme drum, toner, hingga sistem fuser, dapat menyebabkan jenis kebocoran tinta yang berbeda pula. Misalnya, pada beberapa model HP, kebocoran mungkin muncul sebagai garis vertikal tipis, sedangkan pada model Brother bisa berupa penyebaran tinta yang tidak merata di seluruh permukaan kertas. Variasi semacam ini sangat penting untuk dimasukkan ke dalam dataset guna membangun model yang tidak hanya akurat, tetapi juga adaptif terhadap berbagai jenis printer.

Proses dokumentasi hasil cetakan dari masing-masing printer dilakukan secara sistematis dan disimpan dalam format citra digital dengan resolusi tinggi. Citra-citra ini kemudian diproses lebih lanjut dalam tahap preprocessing dan pelabelan. Pemilihan printer yang variatif menjadi fondasi penting dalam membentuk dataset yang komprehensif, sehingga model yang dikembangkan tidak mengalami overfitting pada jenis printer tertentu saja.

b. Kondisi Hasil Cetak


Citra hasil cetakan yang dikumpulkan dalam penelitian ini mencerminkan berbagai kondisi anomali cetakan akibat kebocoran tinta,

yang pada umumnya terjadi karena kerusakan pada komponen internal printer atau penggunaan toner yang tidak sesuai. Setiap kondisi anomali didokumentasikan dengan cermat untuk memberikan variasi visual yang cukup dalam dataset, termasuk di antaranya adalah garis tinta horizontal atau vertikal, bercak tinta di area tertentu, serta cetakan yang tampak buram atau tidak konsisten.

Kondisi hasil cetak diklasifikasikan dalam dua kategori utama berdasarkan tingkat keparahan kerusakan visual yang teridentifikasi. Kategori pertama adalah cetakan “baik” yang menunjukkan hasil normal tanpa adanya gangguan visual. Kategori kedua adalah cetakan “buruk” yang mengindikasikan adanya kebocoran tinta dalam bentuk apapun. Proses klasifikasi ini tidak hanya memudahkan pelabelan data, tetapi juga penting dalam pelatihan model biner untuk mendeteksi keberadaan cacat.

Gambar 3. 3 Contoh Hasil Toner Normal

Gambar 3. 4 Contoh Hasil Toner Habis



Gambar 3. 5 Contoh Hasil Toner Bocor

Setiap citra dalam dataset diambil dari hasil pemindaian (scanning) atau pemotretan dengan resolusi tinggi untuk memastikan setiap detail visual dapat ditangkap oleh model CNN. Kondisi pencahayaan, resolusi kamera, dan sudut pengambilan gambar dikontrol secara ketat untuk menjaga konsistensi antar data. Hasil cetakan yang mengalami kebocoran tinta pada umumnya menunjukkan pola yang tidak teratur, dan oleh karena itu, penting bagi model untuk dilatih menggunakan gambar yang cukup kompleks.


Selain itu, dokumentasi metadata seperti jenis printer, waktu pencetakan, dan kondisi lingkungan juga dicatat sebagai bagian dari analisis lanjutan. Dengan mendokumentasikan kondisi hasil cetak secara menyeluruh, penelitian ini memastikan bahwa model tidak hanya dapat mendeteksi kebocoran, tetapi juga dapat mengidentifikasi pola visual kebocoran berdasarkan ciri-ciri khusus dari masing-masing printer.

c. **Augmentasi Data**

Untuk memperluas jumlah data dan meningkatkan keberagaman fitur visual dalam dataset, dilakukan proses augmentasi data. Augmentasi data adalah teknik dalam ilmu komputer yang digunakan untuk menghasilkan variasi baru dari data yang sudah ada dengan cara melakukan transformasi pada citra asli. Proses ini bertujuan agar model tidak hanya mengenali pola-

pola spesifik pada data pelatihan, tetapi juga dapat melakukan generalisasi terhadap data baru yang memiliki distribusi serupa namun tidak identik.

Beberapa teknik augmentasi yang diterapkan dalam penelitian ini meliputi rotasi citra dalam berbagai derajat, flipping horizontal dan vertikal, translasi (pergeseran) posisi objek dalam citra, serta perubahan intensitas kontras dan pencahayaan. Teknik-teknik ini dipilih karena mampu mensimulasikan berbagai kondisi pengambilan gambar di dunia nyata, seperti hasil scan yang sedikit miring atau perubahan pencahayaan saat pemotretan. Dengan demikian, model akan lebih tangguh terhadap gangguan visual eksternal.



Gambar 3. 6 Sampling Augmentasi Data

Augmentasi data tidak hanya meningkatkan jumlah data pelatihan, tetapi juga berfungsi sebagai metode regularisasi untuk mencegah overfitting, yaitu kondisi di mana model terlalu menghafal data pelatihan sehingga tidak mampu bekerja baik pada data uji. Citra-citra yang telah diaugmentasi

dipastikan tetap mempertahankan label aslinya, sehingga kualitas informasi dalam dataset tetap terjaga. Misalnya, gambar hasil cetakan yang buruk tetap diberi label “buruk” meskipun telah diputar atau diterangkan kontrasnya.

Setelah proses augmentasi dilakukan, seluruh citra dikaji ulang untuk memastikan bahwa tidak ada distorsi atau transformasi yang menyebabkan hilangnya informasi penting. Hasil akhir dari augmentasi memberikan kontribusi signifikan dalam meningkatkan performa model CNN, terutama dalam hal akurasi dan ketahanannya terhadap kondisi gambar yang bervariasi.


d. Penyusunan Dataset

Langkah akhir dari proses pengumpulan data adalah penyusunan dan pengorganisasian dataset untuk keperluan pelatihan dan pengujian model. Dataset yang telah dikumpulkan dan diberi label selanjutnya dibagi ke dalam dua kelompok utama, yaitu data pelatihan (training data) dan data pengujian (testing data). Pembagian dilakukan dengan proporsi 80:20, di mana 80% dari total citra digunakan untuk melatih model, dan 20% sisanya digunakan untuk mengevaluasi kinerja model setelah proses pelatihan selesai.

Proses pembagian ini dilakukan secara acak, namun tetap memperhatikan keseimbangan jumlah data pada masing-masing kategori (baik dan buruk), agar model tidak bias terhadap salah satu kelas. Dengan demikian, model CNN dapat belajar secara seimbang dan mampu mengenali kedua kondisi cetakan dengan tingkat presisi yang tinggi. Distribusi yang tidak merata dalam proses pelatihan dapat menyebabkan ketidakseimbangan klasifikasi, yang pada akhirnya menurunkan performa model saat diterapkan pada data nyata.

Setiap bagian dari dataset disimpan dalam struktur folder yang terorganisir, di mana nama folder, nama file, dan metadata lainnya dicatat secara sistematis. Ini memudahkan pelacakan dan analisis lebih lanjut apabila ditemukan kesalahan dalam pelabelan atau hasil prediksi model yang tidak sesuai. Selain itu, dokumentasi ini berguna untuk proses replikasi penelitian atau pengembangan lebih lanjut.

Dengan dataset yang telah disusun secara terstruktur, tahap berikutnya dalam penelitian dapat dilaksanakan dengan dasar data yang kuat. Model CNN yang akan dikembangkan diharapkan dapat memperoleh pemahaman mendalam terhadap pola visual kebocoran tinta dari hasil cetak printer laser, serta memiliki akurasi tinggi dalam mendeteksi kondisi cetak yang cacat maupun yang normal.



Gambar 3. 7 Flowchart Pengumpulan Data

3.6 Persiapan Data

3.6.1 Keterangan Data

Data yang digunakan dalam penelitian ini terdiri atas kumpulan citra hasil cetakan dari printer laser yang diambil menggunakan pemindai

(scanner) beresolusi tinggi. Pemindaian dilakukan untuk menangkap kualitas hasil cetak secara detail, termasuk distribusi tinta, ketebalan cetakan, dan keberadaan cacat visual seperti noda atau garis-garis tidak beraturan. Setiap citra tersebut kemudian dianotasi secara manual oleh dua validator independen guna memastikan objektivitas klasifikasi serta meminimalkan bias manusia dalam proses labeling.

Tiga kategori label yang digunakan dalam klasifikasi ini adalah **normal**, **habis**, dan **bocor**. Kelas **normal** menunjukkan hasil cetakan yang jelas, merata, dan tanpa cacat visual; kelas **habis** ditandai dengan hasil cetakan yang kabur, tipis, atau bahkan tidak tercetak; sedangkan kelas **bocor** dicirikan oleh munculnya noda tinta, garis gelap berulang, atau sebaran tinta yang tidak semestinya.

Pemilihan label-label ini mengacu pada kondisi nyata yang sering ditemui di industri percetakan, khususnya di lingkungan kerja PT XYZ yang menggunakan printer laser untuk operasional produksi harian. Validitas kategori diperoleh dari pengalaman teknisi lapangan serta studi pendahuluan terhadap kerusakan hasil cetakan yang umum terjadi.

Fitur (Input)	Keterangan
Nama Gambar	Nama file citra hasil scan dari cetakan printer.
Label Kelas	Kategori kondisi hasil cetakan: bocor, habis, atau normal.
Sumber Printer	Merek atau tipe printer (Canon, HP, Brother) yang digunakan untuk mencetak citra tersebut.
Resolusi (dpi)	Resolusi hasil pemindaian gambar, misalnya 300 dpi.
Format File	Format penyimpanan gambar (JPG/PNG), digunakan dalam preprocessing oleh CNN.

Fitur (Input)	Keterangan
Ukuran Gambar (px)	Ukuran citra setelah proses resize, yaitu 150×150 piksel sesuai input layer model CNN.
Brightness	Tingkat pencahayaan rata-rata dari gambar, digunakan dalam augmentasi (jika diperlukan).
Augmentasi	Informasi apakah gambar termasuk hasil augmentasi (rotasi, flip, zoom), bernilai True atau False.
Tanggal Upload	Tanggal citra diunggah ke sistem untuk klasifikasi.
Prediksi Kelas	Output klasifikasi CNN setelah pelatihan model (bocor, habis, normal).


Tabel 3. 1 Fitur pada dataset

3.6.2 Pengelompokan Data

Proses pengelompokan data dilakukan dengan mempertimbangkan struktur direktori yang kompatibel dengan metode pemrosesan data pada deep learning, khususnya dengan *ImageDataGenerator* milik pustaka Keras. Dataset dibagi ke dalam dua direktori utama, yaitu dataset/train/ untuk data pelatihan dan dataset/validation/ untuk data validasi. Di dalam masing-masing direktori terdapat tiga subfolder sesuai dengan kategori label, yaitu normal/, habis/, dan bocor/. Dengan struktur ini, pembacaan otomatis oleh generator Keras dapat dilakukan tanpa kesalahan, karena label secara implisit diberikan melalui nama folder.

Klasifikasi data ke dalam folder ini tidak hanya membantu dalam manajemen dataset, tetapi juga memperkuat pendekatan *supervised learning*. Penataan ini penting karena proses pelatihan CNN sangat bergantung pada konsistensi antara data input dan label target. Selain itu, struktur ini memungkinkan pengembangan sistem yang lebih modular dan fleksibel,

karena setiap kelas dapat dimanipulasi secara independen—misalnya, untuk proses augmentasi atau balancing data.



Gambar 3. 8 Subfolder Sesuai Dengan Kategori Label

3.6.3 Persiapan Dataset


Sebelum data digunakan dalam proses pelatihan, setiap gambar mengalami prapemrosesan melalui modul ImageDataGenerator. Langkah pertama dalam prapemrosesan adalah normalisasi skala piksel, di mana seluruh nilai piksel dari 0–255 dikonversi menjadi rentang 0–1 menggunakan parameter $\text{rescale}=1./255$. Normalisasi ini bertujuan untuk mempercepat proses pelatihan model, karena jaringan saraf konvolusional lebih stabil saat menerima input dengan nilai yang terstandarisasi (Shorten & Khoshgoftaar, 2021).

Selanjutnya, setiap citra di-*resize* ke ukuran 150×150 piksel agar konsisten dengan dimensi input layer dari model CNN. Ukuran ini dipilih sebagai kompromi antara ketajaman detail citra dan efisiensi komputasi. Jika ukuran terlalu besar, proses pelatihan bisa memakan waktu dan memori yang tinggi; sebaliknya, jika terlalu kecil, maka detail penting pada cetakan seperti garis tipis atau bercak kecil dapat hilang. Menurut penelitian sebelumnya dalam domain klasifikasi citra industri, resolusi sekitar 150×150 terbukti cukup untuk menangkap fitur visual utama (Li et al., 2022)

Proses pembagian data dilakukan secara manual, dengan proporsi **80% data untuk pelatihan** dan **20% untuk validasi**. Teknik ini dimaksudkan untuk mempertahankan keseimbangan antar kelas dalam kedua subset dan menghindari *data leakage*. Hal ini juga sejalan dengan praktik terbaik dalam pelatihan model deep learning, di mana validasi pada data yang tidak dilibatkan dalam proses pelatihan menjadi indikator utama kinerja generalisasi model (J. Chen et al., 2021).




3.7 Kerangka Pemikiran



Gambar 3. 9 Kerangka Pemikiran

3.8 Perancangan UML

3.8.1 Use Case Diagram




Gambar 3. 10 Use Case Diagram

Use Case Diagram menggambarkan hubungan antara aktor (pengguna) dengan fungsionalitas utama sistem. Pada sistem ini, terdapat satu aktor utama, yaitu Petugas QC, yang berinteraksi dengan sistem untuk melakukan berbagai aktivitas terkait pengujian hasil cetakan printer.

Use Case yang Digambarkan:

- Login – Petugas melakukan otentikasi agar dapat mengakses sistem.
- Upload Citra Cetakan – Pengguna mengunggah gambar hasil cetakan untuk diproses.
- Klasifikasi Citra – Sistem menjalankan model CNN untuk memprediksi kondisi cetakan (normal, habis, bocor).
- Tampilkan Hasil & Confidence Score – Sistem memberikan hasil klasifikasi dan tingkat keyakinan (confidence score).
- Simpan Log Riwayat – Sistem menyimpan hasil klasifikasi sebelumnya sebagai dokumentasi.
- Lihat Riwayat Prediksi – Pengguna dapat melihat data hasil klasifikasi terdahulu.

3.8.2 Activity Diagram




Gambar 3. 11 Activity Diagram

Activity Diagram menggambarkan alur aktivitas sistem secara terstruktur dan berurutan. Diagram ini menjelaskan bagaimana proses dimulai dari pengguna hingga klasifikasi citra selesai dan hasil ditampilkan.

Alur Aktivitas:

- a. Pengguna membuka aplikasi web
- b. Login ke sistem
- c. Upload gambar hasil cetakan
- d. Sistem melakukan preprocessing (resize, normalize, augmentasi)
- e. Model CNN memproses gambar
- f. Hasil klasifikasi ditampilkan (normal, habis, bocor)
- g. Confidence score disediakan
- h. Simpan log prediksi ke database
- i. Pengguna dapat melihat hasil klasifikasi dan riwayat

3.8.3 Sequence Diagram



Gambar 3. 12 Sequence Diagram

Sequence Diagram menunjukkan interaksi antara komponen sistem secara berurutan (timeline). Diagram ini fokus pada proses klasifikasi citra saat pengguna mengunggah gambar dan sistem memberikan prediksi.

Komponen Interaksi:


- User
- Web Interface (Flask)
- Preprocessing Module
- CNN Model
- Database

Alur Interaksi:

- User mengunggah citra ke antarmuka web
- Web Flask menerima input dan mengirim ke modul preprocessing
- Preprocessing mengubah ukuran, normalisasi, augmentasi
- Gambar diteruskan ke CNN Model
- Model memberikan hasil prediksi dan confidence
- Web Interface menampilkan hasil kepada pengguna
- Log prediksi disimpan ke Database
- User dapat memilih untuk melihat riwayat hasil

3.9 Rincian Modelling

3.9.1 Flowchart Pelatihan Model



Gambar 3. 13 Flowchart Pelatihan Model

Proses pelatihan model dilakukan secara sistematis dan terstruktur dalam beberapa tahapan, yang dapat digambarkan dalam bentuk diagram alir (*flowchart*) untuk memudahkan pemahaman alur pengembangan. Tahapan pertama adalah inisialisasi model, di mana struktur CNN dibangun menggunakan pendekatan *sequential modeling* dari pustaka `tensorflow.keras.models`. Pemilihan model *sequential* dilakukan karena sifatnya yang linier dan cocok untuk desain arsitektur konvolusional bertahap.

Selanjutnya, dilakukan prapemrosesan data menggunakan `flow_from_directory()` yang secara otomatis membaca gambar dari folder

yang telah diberi label sesuai nama subdirektori, seperti “bocor”, “habis”, dan “normal”. Fungsi ini tidak hanya membaca gambar dan labelnya, tetapi juga menyusun data ke dalam batch dan menyesuaikan dimensi gambar sesuai kebutuhan input layer model.

Setelah data siap, dilakukan kompilasi model menggunakan *optimizer* Adam dengan laju pembelajaran (*learning rate*) sebesar 0.0001. Fungsi *loss* yang digunakan adalah *categorical_crossentropy*, yang sesuai untuk kasus klasifikasi multikelas dengan label *one-hot encoded*. Arsitektur CNN ini kemudian dilatih (*training*) selama 10 epoch, dengan pemantauan kinerja dilakukan secara berkala menggunakan data validasi untuk menghindari *overfitting*.

Pada akhir pelatihan, diterapkan teknik *ModelCheckpoint* untuk menyimpan bobot terbaik (best model) dalam format .h5. Pemilihan model terbaik ditentukan berdasarkan nilai akurasi validasi tertinggi yang dicapai selama proses pelatihan.

3.9.2 Metode Machine Learning

Metode utama yang digunakan dalam penelitian ini adalah *Convolutional Neural Network* (CNN), sebuah pendekatan dalam deep learning yang telah terbukti unggul dalam menangani permasalahan klasifikasi berbasis citra. CNN dikenal efektif dalam mengekstraksi informasi spasial dari gambar, seperti pola tekstur, bentuk, dan intensitas warna, yang sangat relevan dalam mengidentifikasi kualitas hasil cetakan printer.

Struktur arsitektur yang digunakan terdiri dari dua blok *Conv2D* yang masing-masing diikuti oleh *MaxPooling2D*. Blok konvolusi ini berfungsi untuk mengekstraksi fitur penting dari gambar, sedangkan pooling membantu

mengurangi dimensi dan mencegah overfitting. Setelah dua tahap ekstraksi ini, jaringan dilanjutkan dengan layer *flatten* yang mengubah representasi spasial menjadi vektor satu dimensi, kemudian diikuti oleh *dense layer* sebagai classifier akhir. Fungsi aktivasi softmax digunakan pada layer output untuk mengklasifikasikan input ke dalam tiga kelas, yaitu *normal*, *habis*, dan *bocor*, berdasarkan probabilitas maksimum.

CNN dipilih dalam penelitian ini karena sifatnya yang mampu mengenali anomali visual halus, seperti ketidakteraturan tinta dan garis cetakan samar, yang seringkali tidak terdeteksi oleh model pembelajaran tradisional seperti Regresi Linier atau Random Forest. Studi oleh (Kim et al., 2023) menunjukkan bahwa CNN mampu mencapai presisi tinggi pada tugas inspeksi visual berbasis industri, terutama dalam klasifikasi cacat produksi yang memerlukan sensitivitas terhadap fitur-fitur visual minor.

3.9.3 Platform dan Alat untuk Pelatihan Model

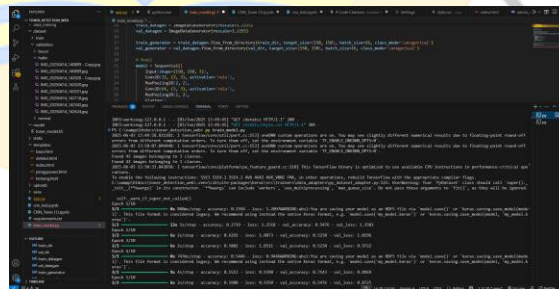
Untuk memastikan efisiensi dalam proses pelatihan model, penelitian ini memanfaatkan platform Google Colaboratory (Colab) sebagai lingkungan utama pengembangan. Google Colab menyediakan akses ke GPU secara gratis, yang sangat diperlukan untuk mempercepat proses komputasi numerik dalam pelatihan CNN. Platform ini juga memungkinkan kolaborasi lintas perangkat dan akses real-time terhadap notebook yang tersimpan di cloud.

Beberapa pustaka dan perangkat lunak penting digunakan dalam proses pelatihan:

- a. TensorFlow & Keras: Menjadi inti dalam arsitektur dan pelatihan model CNN, pustaka ini memungkinkan pembuatan model deep learning secara modular, dengan API intuitif dan fleksibel.

- b. ImageDataGenerator: Digunakan untuk melakukan augmentasi data dan normalisasi nilai piksel gambar. Fungsi ini berperan penting dalam memperkaya variasi dataset dan mengurangi risiko overfitting.
- c. Matplotlib & Seaborn: Digunakan untuk memvisualisasikan metrik pelatihan seperti loss dan akurasi pada data latih dan validasi, serta menyusun confusion matrix untuk evaluasi pascapelatihan.
- d. Flask Framework: Digunakan untuk membangun antarmuka web interaktif yang terintegrasi langsung dengan model CNN, sehingga hasil klasifikasi dapat diakses secara praktis oleh pengguna non-teknis.

Pemanfaatan kombinasi platform cloud dan pustaka open-source ini membuktikan bahwa sistem pembelajaran mendalam dapat dikembangkan secara efisien tanpa harus mengandalkan infrastruktur komputasi mahal. Selain itu, struktur modular pada pengembangan model dan sistem aplikasi mendukung fleksibilitas untuk ekspansi fungsional, seperti penambahan log prediksi atau integrasi database di masa mendatang.



Gambar 3. 14 Tampilan Lingkungan Pengembangan Model pada Visual Studi Code

3.10 Metode Evaluasi

Evaluasi dalam penelitian ini bertujuan untuk mengukur sejauh mana model Convolutional Neural Network (CNN) mampu mengklasifikasikan kualitas hasil cetak printer laser dengan akurasi tinggi. Model dirancang untuk mendeteksi berbagai kondisi hasil cetak, termasuk kebocoran tinta, kondisi

normal, atau hasil cetak buruk lainnya. Evaluasi dilakukan menggunakan sejumlah metrik kinerja dan prosedur yang dirancang untuk memastikan hasil yang valid dan relevan.

3.10.1 Metrik Evaluasi

a. Akurasi (Accuracy)

Akurasi merupakan salah satu metrik evaluasi yang paling dasar dan banyak digunakan untuk mengukur kinerja model klasifikasi. Akurasi didefinisikan sebagai persentase dari jumlah prediksi yang benar (baik positif maupun negatif) dibandingkan dengan total prediksi yang dibuat oleh model. Rumusnya adalah:

$$\text{Akurasi} = \frac{(TP + TN)}{\text{Total Data } (TP + TN + FP + FN)}$$

- **True Positive (TP):** Prediksi hasil cetak "buruk" yang benar.
- **True Negative (TN):** Prediksi hasil cetak "baik" yang benar.
- **False Positive (FP):** Prediksi hasil cetak "buruk" yang salah.
- **False Negative (FN):** Prediksi hasil cetak "baik" yang salah.

Namun, akurasi tidak selalu mencerminkan performa sebenarnya jika dataset tidak seimbang. Misalnya, jika sebagian besar data berada dalam kategori "baik", model dapat mencapai akurasi tinggi hanya dengan memprediksi semua data sebagai "baik". Oleh karena itu, metrik tambahan seperti presisi dan recall diperlukan.

b. Presisi (Precision)

Presisi mengukur seberapa akurat prediksi positif model, yaitu proporsi data yang benar-benar positif dari semua data yang diprediksi sebagai positif. Rumus presisi:

$$Precision = \frac{TP}{TP + FP}$$

Presisi sangat penting dalam situasi di mana kesalahan dalam mendeteksi hasil cetak "buruk" sebagai "baik" dapat berdampak signifikan. Sebagai contoh, dalam pengawasan cetakan penting, presisi yang tinggi memastikan bahwa setiap peringatan benar-benar valid.

c. Recall (Sensitivitas)

Recall, atau sensitivitas, mengukur kemampuan model untuk mendeteksi semua data positif yang sebenarnya. Rumus recall

$$Recall = \frac{TP}{TP + FN}$$

Recall relevan dalam situasi di mana penting untuk memastikan bahwa semua kerusakan atau cacat yang ada terdeteksi, meskipun beberapa prediksi salah muncul. Misalnya, model dengan recall tinggi dapat mengidentifikasi semua hasil cetak buruk, meskipun ada beberapa kesalahan dalam kategori lain.

d. F1-Score

F1-Score adalah metrik yang menggabungkan presisi dan recall menjadi satu angka tunggal, terutama berguna jika ada ketidakseimbangan data. Rumusnya:

$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall}$$

F1-Score sangat penting dalam kasus di mana tidak ada metrik tunggal yang cukup untuk mengevaluasi performa model secara keseluruhan. Model yang memiliki nilai F1-Score tinggi dianggap mampu menangani ketidakseimbangan data dengan baik.

e. Confusion Matrix



Confusion matrix adalah tabel yang menggambarkan kinerja model secara lebih rinci, menampilkan jumlah prediksi yang benar dan salah untuk setiap kategori. Struktur matriksnya adalah sebagai berikut:

	Prediksi Positif (Buruk)	Prediksi Negatif (Baik)
Aktual Positif (Buruk)	True Positive (TP)	False Negative (FN)
Aktual Negatif (Baik)	False Positive (FP)	True Negative (TN)

Tabel 3. 2 Contoh Tabel Confusion Matrix

Matriks ini memberikan pandangan lengkap tentang kemampuan model dalam membedakan antara hasil cetak "baik" dan "buruk".

3.10.2 Metrik Evaluasi

a. Pembagian Dataset

Dataset dibagi menjadi tiga subset utama:


1. **Training Set:** Digunakan untuk melatih model sehingga dapat mengenali pola dari data.
2. **Validation Set:** Berfungsi memantau performa model selama pelatihan, membantu menghindari overfitting.
3. **Testing Set:** Bertindak sebagai alat evaluasi akhir untuk menilai kemampuan model pada data yang benar-benar baru.

Proporsi pembagian dataset biasanya disesuaikan dengan ukuran dataset yang tersedia, misalnya 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian.

b. K-Fold Cross-Validation

K-fold cross-validation adalah metode untuk meningkatkan keandalan evaluasi. Dataset dibagi menjadi k bagian yang sama, di mana setiap bagian bergiliran menjadi data

uji sementara bagian lainnya digunakan untuk pelatihan. Hasil dari setiap iterasi dirata-rata untuk memberikan estimasi performa yang lebih akurat.



Gambar 3. 15 Grafik Akurasi Model CNN

c. Evaluasi dengan Dataset Uji

Dataset uji digunakan untuk mengevaluasi performa model dalam situasi nyata. Data ini tidak pernah digunakan selama pelatihan atau validasi, memastikan bahwa hasil evaluasi mencerminkan kemampuan model untuk generalisasi pada data baru.

3.10.3 Analisis Hasil Evaluasi

Hasil evaluasi dianalisis untuk memahami kekuatan dan kelemahan model:

- Akurasi tinggi, recall rendah:** Model cenderung melewati hasil cetak "buruk" yang penting, meskipun memberikan prediksi yang benar pada sebagian besar data.
- Presisi tinggi, recall rendah:** Model berhati-hati dalam mendeteksi hasil cetak buruk tetapi dapat melewati beberapa kasus penting.
- F1-Score tinggi:** Menunjukkan bahwa model seimbang dalam memberikan hasil akurat dan mendeteksi semua kasus penting.

Setiap metrik dan prosedur evaluasi yang diterapkan memberikan wawasan yang lebih dalam tentang performa model, memastikan bahwa sistem dapat diandalkan dalam berbagai situasi. Dengan pendekatan ini, sistem diharapkan dapat memberikan hasil yang akurat dan bermanfaat bagi pengguna

