

BAB II

TINJAUAN PUSTAKA

2.1 Teori

2.1.1 Teori Umum

2.1.1.1 Alat Pelindung Diri (APD)

Alat pelindung diri atau Pakaian *safety* merupakan peralatan yang digunakan untuk melindungi pekerja konstruksi agar terhindar dari cedera atau mengurangi tingkat keparahan cedera. APD mencakup berbagai perlindungan, seperti helm keselamatan, alas kaki keselamatan, pakaian pelindung, pelindung mata, pelindung telinga, sarung tangan pelindung, sabuk pengaman, dan respirator. Selain itu, APD juga membantu mencegah cedera pada tangan, kaki, kepala, dan mencegah terjatuh dari ketinggian. APD merupakan perlengkapan penting untuk melindungi diri dari berbagai bahaya. APD menjadi langkah terakhir pengamanan jika metode pencegahan lain tidak tersedia atau tidak memungkinkan. Penggunaan APD harus menjadi pilihan terakhir dan hanya digunakan ketika pengendalian risiko melalui mesin menjadi sulit dan tidak efektif. Penting untuk memilih APD yang tepat sesuai dengan jenis bahaya yang ada di tempat kerja untuk memastikan keselamatan dan kesehatan kerja para pekerja. (A and Wang 2022)

Alat pelindung diri tidak hanya melindungi tubuh dari bahaya fisik, seperti terjatuh, tertimpa benda, atau terkena bahan kimia berbahaya, tetapi juga dapat melindungi dari bahaya non-fisik seperti stres dan kelelahan. Penggunaan APD yang tepat dapat membantu menciptakan lingkungan kerja yang lebih aman dan sehat bagi semua orang. (Barro-Torres et al. 2012)

Fungsi utama Alat Pelindung Diri atau pakaian *safety* adalah untuk:

1. Mencegah kecelakaan kerja: APD dapat membantu melindungi pemakainya dari berbagai bahaya di tempat kerja, seperti terjatuh, tertimpa benda, terkena bahan kimia berbahaya, terpapar radiasi, dan lain sebagainya.
2. Menjaga kesehatan: APD juga dapat membantu menjaga kesehatan pemakainya dengan mencegah paparan terhadap debu, asap, dan bahan berbahaya lainnya yang dapat menyebabkan penyakit.
3. Meningkatkan produktivitas: Pegawai yang merasa aman dan nyaman saat bekerja akan lebih produktif dan efisien.

Berikut adalah beberapa jenis APD utama yang umum digunakan:

1. Pelindung pendengaran: *Earplug* atau *earmuff* digunakan untuk mencegah kontak dengan tingkat kebisingan yang tinggi, yang dapat menyebabkan gangguan atau pelemahan pendengaran.
2. Pelindung mata dan wajah: Kacamata pengaman dan *face shield* berfungsi untuk melindungi mata dan wajah dari bahaya ketika terpapar percikan bahan kimia, debu, asap, serpihan benda kecil yang beterbangan, dan radiasi.
3. Pelindung pernapasan: Masker, respirator, atau *self-contained breathing apparatus* (SCBA) digunakan untuk melindungi saluran pernapasan dari bahaya penyakit akibat kerja yang disebabkan oleh debu, kabut, gas, asap, bahan kimia, dan uap berbahaya.

4. Pelindung tangan: Sarung tangan yang terbuat dari berbagai bahan, seperti karet, kulit, atau kain, digunakan untuk melindungi tangan dari bahaya bahan kimia, luka akibat benda tajam, panas, dan dingin.
5. Pelindung kaki: Sepatu *safety* atau boots digunakan untuk melindungi kaki dari bahaya benda tajam, tertimpa benda, dan bahan kimia.
6. Pakaian pelindung: Apron, overall, atau hazmat suit digunakan untuk melindungi seluruh tubuh dari bahaya bahan kimia, percikan api, dan radiasi.
7. Pelindung kepala: Helm melindungi kepala dari benturan, menahan penetrasi, dan menyerap guncangan pukulan. Topi keras adalah salah satu jenis pelindung kepala yang paling umum digunakan.
8. Alat pelindung jatuh: *Safety harness*, *safety belt*, dan lanyard digunakan saat bekerja di ketinggian untuk membantu mencegah jatuh atau meminimalkan cedera akibat jatuh.

Jenis APD yang digunakan akan tergantung pada jenis pekerjaan dan bahaya yang terkait dengan pekerjaan tersebut. Penting untuk memilih APD yang tepat dan menggunakannya dengan benar untuk memastikan keamanan dan kesehatan di tempat kerja. (Ammad et al. 2021)

2.1.2 Teori Khusus

2.1.2.1 *Machine Learning*

Pembelajaran Mesin atau *Machine Learning* merupakan pendekatan komputasi yang menggunakan algoritma untuk membantu sistem komputer dalam mempelajari pola dari data dan memperbaiki kinerja secara otomatis. Pembelajaran mesin banyak diterapkan dalam berbagai konteks aplikasi, termasuk pengenalan pola, analisis data, dan pemodelan statistik. Algoritma pembelajaran mesin memiliki variasi kekuatan, keunggulan, dan kelemahan yang berbeda, dan pemilihan algoritma yang tepat tergantung pada masalah yang dihadapi.

Machine learning adalah cabang dari kecerdasan buatan yang memungkinkan sistem untuk belajar dari data, mengidentifikasi pola, dan mengambil keputusan dengan sedikit intervensi manusia. Algoritma ini memungkinkan komputer untuk menemukan wawasan baru dan memprediksi nilai output berdasarkan variabel input yang diberikan. Dalam pengembangan model *machine learning*, melatih algoritma dengan lebih banyak data cenderung menghasilkan jawaban yang lebih akurat. Algoritma ini juga memainkan peran penting dalam mengotomatisasi tugas, mengurangi waktu respons, dan meningkatkan kepuasan pelanggan.

Dalam pembelajaran mendalam (*deep learning*), algoritma dapat menyerap data yang tidak terstruktur, seperti teks atau gambar, dan secara otomatis mengidentifikasi fitur yang membedakan kategori data. Hal ini memungkinkan penggunaan kumpulan data yang lebih besar dan mengurangi campur tangan manusia dalam proses pembelajaran. Dengan demikian, machine learning menjadi inti dari banyak aplikasi kecerdasan buatan yang sukses. (Zhang and A 2023)

2.1.2.2 *Deep learning*

Deep learning adalah metode pembelajaran mesin yang menggunakan algoritma dengan jaringan neuron yang tidak terstruktur. Metode ini memanfaatkan tahap pembelajaran yang lebih tinggi untuk mengidentifikasi dan memproses data. Dalam sebuah artikel, metode *deep learning* berbasis *Convolutional Neural Network* (CNN) digunakan untuk mendeteksi tumor otak dari gambar MRI. Hasilnya menunjukkan akurasi mencapai 99,74%, yang lebih baik daripada hasil sebelumnya penerapan metode ini akan membantu para dokter dalam mendeteksi tumor otak secara akurat pada gambar MRI, sehingga kecepatan dalam pengobatan meningkat pesat.

Metode *deep learning* berbasis *Convolutional Neural Network* (CNN) merupakan salah satu jenis arsitektur neural network yang khusus dirancang untuk tugas-tugas yang memerlukan pengenalan objek, termasuk klasifikasi gambar, deteksi objek, dan segmentasi. CNN digunakan dalam berbagai skenario praktis, seperti kendaraan otonom, sistem kamera keamanan, dan lainnya.

Berikut beberapa alasan mengapa CNN penting dalam dunia modern:

1. Ekstraksi Fitur Otomatis: CNN dapat mengambil fitur secara otomatis dalam skala besar, menghindari kebutuhan untuk menggunakan teknik rekayasa fitur manual dan dengan demikian meningkatkan efisiensi.
2. Karakteristik Invarian Terhadap Translasi: Lapisan konvolusi memberikan karakteristik invarian terhadap translasi, memungkinkan

CNN untuk mengidentifikasi dan mengekstrak pola dan fitur dari data tanpa memperhatikan variasi posisi, orientasi, skala, atau translasi.

3. **Arsitektur Pre-Trained:** Arsitektur CNN seperti VGG-16, ResNet50, Inceptionv3, dan EfficientNet telah menunjukkan kinerja terbaik. Model-model ini dapat disesuaikan dengan tugas baru melalui proses fine-tuning.

Selain tugas klasifikasi gambar, CNN juga dapat diterapkan pada berbagai domain lain, seperti pemrosesan bahasa alami, analisis deret waktu, dan pengenalan suara. (Chattopadhyay and Maitra 2022)

2.1.2.3 Python

Python, bagaikan pisau Swiss Army multifungsi di dunia pemrograman, menawarkan perpustakaan khusus untuk berbagai disiplin ilmu. Kemampuannya dalam pra-pemrosesan dan pasca-pemrosesan data dalam simulasi numerik, aplikasi AI, dan integrasi model seperti yang ditunjukkan dalam makalah ini, menjadikan Python sebagai alat yang sangat berharga bagi para peneliti.

Meskipun Python tidak akan sepenuhnya menggantikan bahasa ilmiah lain seperti Fortran atau C, dengan keunggulan bawaannya dan basis kode warisan yang luas, Python memainkan peran penting sebagai fasilitator aksesibilitas. Dalam contoh ini, Python, sebagai bahasa skrip yang mudah dipelajari, berfungsi sebagai jembatan penghubung antara bahasa pemrograman prosedural, mendorong kolaborasi dan inovasi dalam komunitas ilmiah. Python adalah bahasa pemrograman yang kuat, serbaguna, dan mudah dipelajari yang telah menjadi alat

penting bagi para peneliti di berbagai disiplin ilmu. Kemampuannya dalam integrasi data, pemodelan, dan analisis menjadikan Python sebagai fasilitator kolaborasi dan inovasi dalam komunitas ilmiah. (Anastasia et al. 2024)

2.1.2.4 Computer Vision

Visi komputer adalah cabang ilmu komputer yang berfokus pada pengembangan algoritma dan teknologi untuk memproses, menganalisis, dan memahami data visual dari dunia nyata, seperti gambar dan video. Dalam hal ini, mesin memiliki kemampuan untuk mengenali objek, klasifikasi gambar, segmentasi, dan pelacakan dengan cara yang serupa dengan persepsi visual manusia.

Konsep visi komputer didasarkan pada pengajaran komputer untuk memproses gambar pada tingkat piksel dan memahaminya. Secara teknis, mesin berusaha untuk mengambil informasi visual, menanganinya, dan menginterpretasikan hasil melalui algoritme perangkat lunak khusus. Tujuan utamanya adalah menciptakan sistem yang dapat menganalisis data visual secara akurat dan efisien, membantu manusia dalam mengambil keputusan, serta mengotomatisasi tugas-tugas yang saat ini dilakukan secara manual.

Visi komputer digunakan dalam berbagai aplikasi, termasuk:

1. Kendaraan otonom: Untuk membantu mobil dan kendaraan lainnya dalam mengenali jalan, menghindari rintangan, dan berinteraksi dengan lingkungan sekitar.

2. Pencitraan medis: Dalam diagnosis dan analisis gambar medis seperti MRI, CT scan, dan pemindaian lainnya.
3. Pengawasan keamanan: Untuk mendeteksi perilaku mencurigakan atau mengidentifikasi wajah pada kamera pengawasan.
4. Robotika: Dalam navigasi robot dan interaksi dengan objek di sekitarnya.
5. Augmented reality: Untuk menggabungkan dunia fisik dengan elemen digital melalui tampilan visual.

Penggunaan pembelajaran mesin dan teknik pembelajaran mendalam membantu melatih model untuk mengenali pola dan membuat prediksi berdasarkan data visual, sehingga menciptakan sistem yang semakin cerdas dan efisien. Dengan visi komputer, kita dapat memperluas batas kemampuan komputer dalam memahami dan berinteraksi dengan dunia visual. (Ciranni et al. 2024)

Visi komputer, bagaikan mata digital yang canggih, menggunakan teknik pemrosesan gambar mutakhir seperti CLAHE dan metode Otsu untuk menganalisis dan memahami keberadaan kekosongan pada komposit serat karbon kontinu yang dicetak 3D. Teknik ini mampu menghasilkan analisis yang lebih presisi dan terstandarisasi dibandingkan dengan metode manual, dengan deviasi standar yang jauh lebih kecil. Visi komputer memungkinkan penentuan karakteristik void yang detail, seperti luas, keliling, eksentrisitas, dan lokasi pusat, sehingga memberikan wawasan mendalam tentang struktur material. Teknik ini dapat diterapkan pada berbagai sistem komposit yang diperkuat serat kontinu dengan rongga mikrostruktural, dan berpotensi mengoptimalkan parameter proses pencetakan 3D

untuk mencapai tingkat produksi komponen yang tinggi dan konten rongga yang rendah. Visi komputer bekerja dengan cara mengambil gambar dan menganalisisnya menggunakan algoritma yang kompleks. Algoritma ini mampu mengidentifikasi objek, pola, dan tekstur dalam gambar, dan kemudian mengekstraksi informasi yang relevan. Terdapat berbagai jenis teknik visi komputer, seperti pengenalan gambar, pelacakan objek, dan segmentasi gambar. Masing-masing jenis memiliki fungsi dan aplikasi yang berbeda. (Galos and Wang 2024)

2.1.1.5 Artificial Intelligence

Kecerdasan Buatan (AI) telah menjadi topik hangat dalam dunia teknologi, mengacu pada kemampuan mesin untuk meniru atau meniru kecerdasan manusia. Teknologi ini bukan hanya tentang replikasi kemampuan fisik manusia, tetapi juga tentang kemampuan untuk belajar, bernalar, dan memecahkan masalah seperti yang dilakukan manusia. AI mencakup berbagai bidang penelitian, seperti pembelajaran mesin dan pembelajaran mendalam, dan telah diterapkan di berbagai industri di seluruh dunia. Dalam konteks Manajemen Sumber Daya Manusia (MSDM), AI memiliki aplikasi yang luas dan potensial untuk meningkatkan berbagai proses dan fungsi. Berikut beberapa contoh penerapan AI dalam MSDM meliputi:

1. Otomatisasi tugas rutin: AI dapat mengotomatisasi tugas-tugas berulang dan padat karya, seperti penyaringan resume, administrasi karyawan, dan pemrosesan data. Hal ini membebaskan staf MSDM untuk fokus pada tugas yang lebih strategis dan bernilai tambah.

2. Peningkatan pengambilan keputusan: AI dapat menganalisis data besar untuk mengidentifikasi pola dan tren, membantu pengambil keputusan dalam MSDM membuat keputusan yang lebih terinformasi dan efektif. Contohnya, AI dapat membantu dalam hal rekrutmen, seperti mengidentifikasi kandidat yang paling sesuai dengan lowongan pekerjaan, atau dalam hal pelatihan, seperti merekomendasikan program pelatihan yang paling sesuai dengan kebutuhan individu karyawan.
3. Personalisasi pengalaman karyawan: AI dapat digunakan untuk mempersonalisasi pengalaman karyawan, seperti memberikan rekomendasi pelatihan yang disesuaikan, atau menyediakan dukungan karyawan yang lebih efektif.
4. Meningkatkan efisiensi dan efektivitas: AI dapat membantu meningkatkan efisiensi dan efektivitas berbagai proses MSDM, seperti perekrutan, pelatihan, dan manajemen kinerja. Hal ini dapat mengarah pada pengurangan biaya dan peningkatan produktivitas.

Meskipun AI menawarkan banyak manfaat potensial bagi MSDM, penting untuk mempertimbangkan beberapa tantangan dan pertimbangan antara lain:

1. Etika dan bias: AI harus diterapkan secara etis dan bertanggung jawab, dengan mempertimbangkan potensi bias dan diskriminasi.
2. Dampak pada pekerjaan: AI dapat mengotomatisasi beberapa pekerjaan, yang dapat berdampak pada tenaga kerja MSDM. Penting

untuk mempertimbangkan strategi untuk mendukung pekerja yang terkena dampak.

3. Keterampilan dan pelatihan: Staf MSDM perlu memiliki keterampilan dan pelatihan yang tepat untuk menggunakan dan mengelola teknologi AI secara efektif.
4. Transparansi dan akuntabilitas: Keputusan yang dibuat oleh AI harus transparan dan akuntabel.
5. Kecerdasan Buatan (AI) memiliki potensi untuk merevolusi berbagai aspek Manajemen Sumber Daya Manusia (MSDM). Dengan penerapan yang cermat dan etis, AI dapat membantu meningkatkan efisiensi, efektivitas, dan pengambilan keputusan dalam MSDM. Namun, penting untuk mempertimbangkan tantangan dan pertimbangan yang terkait dengan AI, seperti dampak pada pekerjaan, etika, dan keterampilan yang dibutuhkan. (Vrontis et al. 2022)

2.1.1.6 TensorFlow

TensorFlow bagaikan landasan peluncuran untuk menjelajahi dunia kecerdasan buatan. Platform ini memungkinkan para ilmuwan data untuk merancang dan melatih model pembelajaran mendalam yang kompleks dengan definisi khusus, dan memanfaatkan kekuatan pemrosesan mutakhir seperti GPU dan TPU. Arsitekturnya yang berlapis dengan API tingkat rendah bekerja sama dengan perangkat keras seperti CPU, GPU, dan TPU untuk mempercepat proses pelatihan dan penerapan model pembelajaran mendalam. Operator TensorFlow

menyediakan algoritma yang efisien untuk algoritma pembelajaran mesin, versi terbarunya adalah TensorFlow 2.16.1 yang mengalami peningkatan signifikan dibandingkan versi sebelumnya. sehingga memudahkan penambahan lapisan baru ke dalam arsitektur model yang diinginkan. (Devrim Akgun, Sakarya et al. 2022)

TensorFlow, sebuah platform pembelajaran mendalam, digunakan untuk mengeksplorasi kerentanan perangkat lunak. Filus dan Domanska menerapkan TensorFlow untuk menghubungkan tingkat keparahan kerentanan dengan deskripsinya, memanfaatkan pembelajaran mendalam dan representasi vektor. Penelitian ini juga mencakup analisis deskripsi kerentanan dan solusinya dari CVE Details.com dan TensorFlow Github Advisory. Selain itu, Filus dan Domanska melakukan validasi, analisis formal, investigasi, dan interpretasi semantik terhadap TensorFlow. Mereka menemukan bahwa TensorFlow rentan terhadap dereferensi penunjuk nol jika tensor oleh kerentanan standar C/C++ dalam implementasinya. Penelitian ini juga menganalisis deskripsi teks kerentanan dan kode sumber untuk menilai kecukupan peringatan per file. Analisis karakteristik masalah terkait NULL Pointer Dereference (CWE-476) dan Integer Overflow dalam aplikasi C/C++ dilakukan, menunjukkan bahwa TensorFlow dapat menimbulkan masalah keamanan. (Katarzyna Filus, Joanna Domanska. 2016)

2.1.2.7 Citra Digital

Citra digital adalah representasi visual dari suatu objek, orang, atau pemandangan yang disimpan dalam bentuk matriks dengan menggunakan elemen

sel titik yang jumlahnya terbatas, biasanya disebut piksel. Citra digital dapat diklasifikasikan menjadi dua kategori:

1. Gambar raster atau Bitmap: Gambar ini merupakan array persegi panjang yang berisi nilai sampel atau piksel. Dalam gambar raster, setiap piksel memiliki nilai intensitas yang menentukan warna atau tingkat keabuan pada lokasi tersebut. Format file gambar raster umumnya meliputi bmp, .gif, .jpeg, .png, dan tiff. Contoh gambar raster adalah foto-foto yang Anda lihat di internet dan gambar yang diambil oleh kamera digital.
2. Gambar vektor: Gambar vektor dihasilkan dari perpaduan titik dan garis dengan menggunakan perhitungan matematika. Titik-titik ini membentuk poligon dan menunjukkan gambaran suatu objek tertentu. Gambar vektor disimpan dalam file dengan berbagai format. Kelebihan gambar vektor adalah kemampuannya untuk diperbesar tanpa kehilangan kualitas karena sifatnya yang skalabel. Contoh format file gambar vektor meliputi svg, eps, dan ai. (Caggiano et al. 2019)

Jadi, perbedaan utama antara gambar raster dan gambar vektor terletak pada cara penyimpanan dan representasi visualnya. Gambar raster menggunakan piksel sebagai elemen dasar, sedangkan gambar vektor menggunakan garis dan kurva matematika. (VipinTyagi. 2018)

2.1.2.8 *Convolutional Neural Network*

Convolutional Neural Network (CNN), atau Jaringan Saraf Tiruan Konvolusi, adalah sebuah teknik canggih untuk pengolahan gambar yang memanfaatkan pembelajaran mendalam untuk menyelesaikan berbagai tugas, baik generatif maupun deskriptif. CNN bekerja dengan struktur yang mirip dengan sistem penglihatan manusia, yang tersusun dari beberapa lapisan, untuk meminimalkan kebutuhan pemrosesan. Jaringan ini dapat diimplementasikan dalam kombinasi perangkat keras dan perangkat lunak, meniru cara kerja neuron di otak manusia. Dibandingkan dengan metode tradisional, CNN menawarkan beberapa keunggulan dalam pengolahan gambar, seperti:

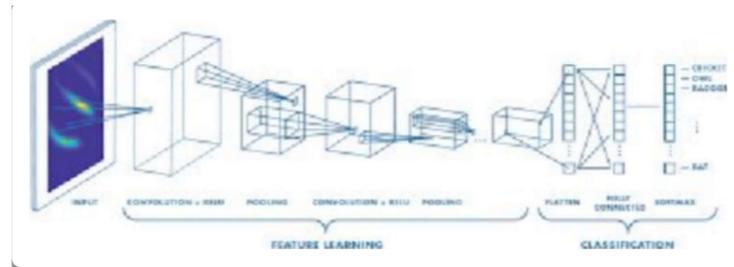
1. Efektivitas yang lebih tinggi: *Convolutional Neural Network* menghasilkan performa yang lebih baik dalam berbagai tugas pengolahan gambar.
2. Kemudahan pelatihan: *Convolutional Neural Network* lebih mudah dilatih dengan data gambar, sehingga memungkinkan pengembangan model yang lebih akurat dan efisien.
3. Potensi luas: *Convolutional Neural Network* dapat diaplikasikan untuk berbagai tugas, termasuk pengenalan pola, klasifikasi gambar, dan pemrosesan bahasa alami.

Convolutional Neural Network (CNN) merupakan salah satu teknik pembelajaran mendalam yang populer dalam pemrosesan dan analisis gambar. CNN dirancang untuk memproses dan mendeteksi pola dalam gambar, menjadikannya sangat efektif untuk tugas-tugas pengenalan objek, klasifikasi

gambar, deteksi, segmentasi objek, dan berbagai aplikasi lain yang melibatkan data visual. Arsitektur CNN terdiri dari beberapa lapisan konvolusi yang berfungsi untuk mengekstrak fitur dari gambar input. Setiap lapisan umumnya terdiri dari operasi konvolusi, pooling (subsampling), dan fungsi aktivasi. Operasi konvolusi menggunakan filter khusus untuk menghasilkan peta fitur, di mana setiap elemen mewakili respons terhadap fitur tertentu dalam gambar. Lapisan pooling kemudian digunakan untuk mengurangi dimensi spasial peta fitur dengan mengambil nilai terbesar atau rata-rata dari suatu wilayah. Hal ini membantu mengurangi kompleksitas komputasi dan mempertahankan informasi penting, meningkatkan efisiensi pemrosesan. Fungsi aktivasi, seperti RELU (Amended Direct Unit), diterapkan untuk memperkenalkan non-linearitas ke dalam model.

Hal ini memungkinkan CNN untuk mempelajari hubungan yang lebih kompleks dan meningkatkan kemampuannya dalam menangkap pola yang rumit dalam gambar. Setelah serangkaian lapisan konvolusi dan pooling, hasil peta fitur diubah menjadi vektor dan diteruskan ke lapisan fully connected untuk klasifikasi atau tugas lain. CNN dilatih melalui proses iteratif yang melibatkan penyesuaian bobot dan bias menggunakan metode backpropagation. Gradien error dihitung dan digunakan untuk mengoptimalkan parameter model, memungkinkan CNN untuk terus belajar dan meningkatkan kemampuannya dalam mengenali pola dalam gambar. Kemampuan CNN dalam memanfaatkan struktur spasial informasi dan memahami pola hierarkis dalam gambar menjadikannya alat yang sangat efektif untuk berbagai tugas pengolahan citra dan pengenalan pola visual. CNN telah banyak digunakan dalam berbagai aplikasi seperti pengenalan wajah, deteksi objek

dalam video, segmentasi gambar medis, dan analisis citra satelit. (Chattopadhyay and Maitra 2022)



Gambar 2.1 Tahapan Algoritma CNN

2.1.2.9 Evaluation Measurement (Pengukuran Evaluasi)

Evaluation Measurement merujuk pada langkah-langkah sistematis pengumpulan, pengolahan, dan penyimpulan informasi mengenai suatu objek atau fenomena. Tujuan utamanya adalah menentukan nilai atau implikasi perilaku berdasarkan hasil pengukuran dan penilaian yang dilakukan. Proses evaluasi estimation melibatkan penilaian terhadap suatu objek dengan merujuk pada kriteria yang telah ditetapkan sebelumnya. Pengukuran, sebagai unsur kunci, melibatkan perbandingan hasil pengamatan dengan kriteria yang telah ditetapkan. Sementara itu, penilaian adalah kegiatan interpretasi dan deskripsi hasil pengukuran tersebut. Metode yang akan digunakan pada penelitian ini adalah recal, accuracy dan precision.

Recal adalah perbandingan yang benar antara prediksi positif dan keseluruhan information positif yang sebenarnya. Dalam konteks klasifikasi, review memberikan jawaban untuk pertanyaan "Berapa persentase dari total data aktual yang berhasil diprediksi dengan benar oleh model?" Konsep ini bermanfaat dalam

menilai kemampuan demonstrate untuk mengidentifikasi seluruh contoh yang seharusnya dianggap positif. Berikut adalah referensi matriks confusion yang menampilkan prediksi dan kondisi sebenarnya dari information yang dihasilkan oleh algoritma yang telah digunakan.

Table 2.1 Matriks Confusion

	Prediksi Positif	Prediksi Negatif
Aktual Positif	True Positif (TP)	False Negatif
Aktual Negatif	False Positif	True Negatif

Dalam tabel ini, terdapat empat istilah yang merupakan representasi hasil proses klasifikasi pada Confusion Matrix, yaitu:

True Positive (TP): Jumlah information yang bernilai Positif dan diprediksi benar sebagai Positif. False Positive (FP): Jumlah information yang bernilai Negatif tetapi diprediksi sebagai Positif. False Negative (FN): Jumlah information yang bernilai Positif tetapi diprediksi sebagai Negatif. True Negative (TN): Jumlah information yang bernilai Negatif dan diprediksi benar sebagai Negatif. Berdasarkan rumus yang ditemukan, review (r) dapat dihitung dengan rumus:

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

Sementara itu, precision (p) dapat dihitung dengan rumus:

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

Kedua formula ini digunakan untuk mengevaluasi performa demonstrasi klasifikasi dalam memproyeksikan kelas positif. Recall mengukur tingkat kemampuan model dalam mengenali seluruh contoh yang seharusnya diprediksi sebagai positif, sementara accuracy mengukur tingkat ketepatan demonstrasi dalam mengidentifikasi contoh yang seharusnya positif dengan akurat.

Presisi, dalam klasifikasi mengukur kemampuan model untuk membedakan antara contoh positif dan negatif. Metrik ini dihitung sebagai proporsi hasil positif yang benar-benar positif. Nilai presisi yang tinggi menunjukkan bahwa model jarang menghasilkan hasil positif palsu, sehingga menjadikannya metrik yang penting untuk mengevaluasi performa model, terutama dalam situasi di mana positif palsu dapat menimbulkan konsekuensi yang signifikan.

Akurasi, dalam klasifikasi merupakan indikator yang menunjukkan kemampuan model untuk memprediksi data dengan benar. Metrik ini dihitung dengan membagi jumlah prediksi yang benar dengan total jumlah data. Nilai akurasi yang tinggi menunjukkan bahwa model mampu mengidentifikasi contoh positif dan negatif dengan tepat. Akurasi menjadi metrik yang penting untuk mengevaluasi performa model, terutama dalam situasi di mana misklasifikasi dapat menimbulkan konsekuensi yang signifikan. Akurasi dihitung dengan rumus berikut:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{FN} + \text{TN}}$$

2.2 Kerangka Pemikiran

2.2.1 Pemahaman Masalah

Beberapa masalah yang ingin di pecahkan pada pakaian *safety* di PT JAYATAMA SAFETINDO:

1. Identifikasi pakaian *safety* yang salah: Di lokasi konstruksi dan lingkungan industri lainnya, sangat penting untuk memastikan bahwa pekerja menggunakan peralatan keselamatan yang tepat untuk mencegah kecelakaan dan cedera. Namun, metode tradisional untuk mengidentifikasi peralatan keselamatan, seperti inspeksi visual, dapat rentan terhadap kesalahan karena faktor manusia seperti kelelahan atau gangguan.
2. Pemantauan keselamatan yang tidak memadai: Memantau kepatuhan pekerja terhadap peraturan keselamatan secara manual dapat memakan waktu dan tenaga. Hal ini dapat menyebabkan kelalaian dalam penegakan keselamatan dan meningkatkan risiko kecelakaan.
3. Kurangnya data waktu nyata: Metode pemantauan keselamatan tradisional sering kali tidak memiliki kemampuan untuk menyediakan data waktu nyata mengenai kepatuhan pekerja terhadap keselamatan. Hal ini dapat menyulitkan untuk mengidentifikasi dan mengatasi bahaya keselamatan secara tepat waktu.

Convolutional Neural Networks (CNN) adalah jenis algoritme pembelajaran mesin yang cocok untuk tugas klasifikasi gambar. Dengan menggunakan CNN, dimungkinkan untuk mengembangkan sistem yang dapat secara otomatis

mengidentifikasi objek dengan pakaian *safety* dalam gambar. Hal ini dapat membantu mengatasi masalah kesalahan identifikasi, pemantauan keselamatan yang tidak efisien, dan kurangnya data waktu nyata.

Penerapan CNN secara spesifik dalam konteks identifikasi pakaian *safety* di PT JAYATAMA SAFETINDO dapat melibatkan langkah-langkah berikut:

1. Pengumpulan data: Kumpulan data yang besar dari gambar pekerja yang mengenakan peralatan keselamatan perlu dikumpulkan. Kumpulan data ini harus mencakup berbagai kondisi pencahayaan, latar belakang, dan pose.
2. Anotasi data: Gambar yang terkumpul perlu dianotasi secara manual untuk mengidentifikasi objek yang mengenakan pakaian keselamatan. Proses anotasi ini akan memberikan data kebenaran dasar yang perlu dipelajari oleh CNN.
3. Pelatihan CNN: CNN akan dilatih pada kumpulan data gambar yang telah dianotasi. Proses pelatihan ini akan melibatkan penyesuaian bobot koneksi CNN untuk meminimalkan kesalahan antara prediksi CNN dan label ground truth.
4. Penyebaran: CNN yang telah dilatih kemudian dapat disebar ke aplikasi dunia nyata, seperti sistem kamera keamanan atau aplikasi seluler. CNN dapat digunakan untuk menganalisis gambar secara real time dan mengidentifikasi objek dengan pakaian *safety*.
5. Evaluasi: Kinerja CNN perlu dievaluasi untuk memastikan bahwa CNN memenuhi persyaratan akurasi aplikasi. Evaluasi ini dapat

melibatkan pengujian CNN pada kumpulan data gambar terpisah yang tidak digunakan untuk pelatihan.

6. Dengan menerapkan sistem identifikasi peralatan keselamatan berbasis CNN, PT JAYATAMA SAFETINDO dapat meningkatkan akurasi dan efisiensi praktik pemantauan keselamatan dan mengurangi risiko kecelakaan dan cedera.

2.2.2 Pengumpulan Data

Pengumpulan data merupakan langkah penting dalam pengembangan *deep learning* untuk mendeteksi gambar berpakaian *safety* dan tidak *safety* di PT JAYATAMA SAFETINDO. Berikut adalah beberapa langkah yang digunakan untuk mengumpulkan dataset.

1. Identifikasi kategori pakaian *safety*: identifikasi pakaian *safety* berupa Helm, Rompi, Sarung tangan, Sepatu *safety*.
2. Kerjasama dengan PT JAYATAMA SAFETINDO: Kolaborasi dengan karyawan untuk memahami kriteria berpakaian *safety* yang sesuai dengan standart perusahaan
3. Penentuan jumlah dan variasi sampel: tentukan jumlah sampel yang cukup besar untuk setiap kategori berpakaian *safety* yang ditetapkan.
4. Fotografi: ambil foto dari setiap sampel dengan kualitas yang memadai.
5. Data augmentasi: melakukan pertimbangan augmentasi data untuk menambah variasi dalam dataset.

2.2.3 Preprocessing Data

Preprocessing Data merupakan langkah penting dalam pelatihan model *deep learning*. Proses ini bertujuan untuk mempersiapkan data sehingga dapat digunakan secara optimal oleh model dan menghasilkan hasil yang lebih baik. *Preprocessing data* yang efektif memastikan data pelatihan berkualitas tinggi dan bebas dari noise, sehingga model dapat belajar dengan lebih efektif dan efisien. Beberapa langkah utama dalam *preprocessing data* meliputi:

1. **Pembersihan Data:** Tahap ini bertujuan untuk menghilangkan data yang tidak valid, tidak relevan, atau rusak. Data yang tidak valid dapat berupa nilai kosong, outlier, atau duplikat. Data yang tidak relevan dengan tujuan pelatihan juga harus dihapus, karena dapat membingungkan model dan menghambat proses pembelajaran.
2. **Normalisasi Data:** Normalisasi data bertujuan untuk mengubah nilai data agar berada dalam rentang yang sama. Hal ini penting untuk memastikan semua fitur memiliki skala yang sama dan model dapat belajar dengan konsisten.
3. **Augmentasi Data:** Augmentasi data bertujuan untuk meningkatkan jumlah data pelatihan dengan cara membuat data baru dari data yang ada. Teknik augmentasi data yang umum digunakan antara lain rotasi, pemotongan, dan penambahan noise. Augmentasi data dapat membantu model belajar lebih baik dan mengurangi risiko overfitting.

Preprocessing Data yang tepat dapat meningkatkan performa model *deep learning* secara signifikan. Dengan memastikan data pelatihan berkualitas tinggi,

model dapat belajar dengan lebih efektif dan menghasilkan prediksi yang lebih akurat.

2.2.4 Pemisahan Data

Dalam pelatihan model *deep learning*, pemisahan data merupakan langkah penting untuk memastikan model belajar dan berkinerja dengan baik. Proses ini melibatkan pembagian data menjadi subset yang berbeda, dengan masing-masing subset digunakan untuk tujuan yang spesifik. Pada kasus deteksi pakaian *safety* dengan *deep learning* menggunakan *TensorFlow* di PT JAYATAMA SAFETINDO, pemisahan data menjadi tiga subset utama adalah langkah yang tepat:

1. **Set Train:** Subset ini digunakan untuk melatih model. Set train harus terdiri dari sebanyak mungkin data yang mewakili semua kategori kualitas pakaian *safety*. Hal ini penting agar model dapat berkinerja dengan baik dan mampu mengenali berbagai variasi pakaian *safety*.
2. **Set Tes:** Subset ini digunakan untuk mengevaluasi kinerja model selama pelatihan. Set tes tidak boleh digunakan untuk melatih model, melainkan hanya untuk menguji kemampuan model dalam mengklasifikasikan data baru yang belum pernah dilihat sebelumnya.

Pemisahan data dapat dilakukan secara manual atau menggunakan perangkat lunak. Untuk pemisahan data manual, data dapat dikelompokkan berdasarkan kategori kualitas. Kelompok-kelompok ini kemudian dapat digunakan sebagai set pelatihan, validasi, dan uji.

2.2.5 Arsitektur Model

Dalam dunia *deep learning*, arsitektur model merupakan elemen fundamental yang menentukan bagaimana data diproses dan diinterpretasikan oleh model. Pemilihan arsitektur yang tepat menjadi kunci untuk mencapai performa optimal dalam berbagai tugas, termasuk deteksi pakaian *safety*. Untuk kasus deteksi pakaian *safety* menggunakan *deep learning* dan *TensorFlow* di PT JAYATAMA SAFETINDO, *Convolutional Neural Network (CNN)* merupakan arsitektur model yang ideal. CNN dirancang khusus untuk tugas-tugas pengenalan visual, di mana model mempelajari pola dan ciri khas dalam data gambar. Kemampuan CNN dalam menangkap detail visual seperti tepi, garis, dan bentuk menjadikannya pilihan tepat untuk mendeteksi pakaian *safety* secara akurat. Pemilihan arsitektur model yang tepat harus mempertimbangkan kompleksitas masalah dan ukuran dataset yang tersedia. Untuk masalah yang kompleks seperti deteksi pakaian *safety*, diperlukan arsitektur model yang lebih kompleks dengan kemampuan ekstraksi fitur yang mendalam. Sebaliknya, untuk dataset yang besar, diperlukan arsitektur model yang efisien dalam menangani volume data yang besar.

2.2.6 Pelatihan Model

Pelatihan model merupakan proses fundamental dalam *deep learning*, di mana model belajar dan berkembang dengan memanfaatkan data pelatihan. Proses ini berlangsung melalui iterasi berulang, di mana model diperbarui dan disempurnakan berdasarkan data yang diberikan.

Dalam konteks deteksi pakaian *safety* menggunakan *deep learning* dan *TensorFlow* di PT JAYATAMA SAFETINDO, beberapa faktor penting perlu diperhatikan untuk memastikan pelatihan model yang efektif:

1. **Kualitas Data Pelatihan:** Pastikan data pelatihan berkualitas tinggi dan merepresentasikan semua kategori kualitas yang ingin dideteksi. Hal ini penting untuk membantu model belajar secara menyeluruh dan akurat.
2. **Ukuran Data Pelatihan:** Gunakan data pelatihan dalam jumlah yang cukup besar. Semakin banyak data yang tersedia, semakin baik model dalam mempelajari pola dan ciri khas pakaian *safety*.
3. **Parameter Pelatihan:** Pilih parameter pelatihan yang tepat untuk mencapai performa optimal. Parameter ini dapat meliputi jumlah layer, ukuran layer, jenis aktivasi, jenis pooling, dan jenis konvolusi.

Dalam pelatihan model *deep learning*, pemilihan parameter yang tepat merupakan kunci untuk mencapai performa optimal. Berikut adalah beberapa contoh parameter pelatihan yang dapat disesuaikan untuk meningkatkan performa model:

1. **Jumlah Layer (Jumlah Lapisan):** Jumlah layer menentukan kompleksitas model. Semakin banyak layer, semakin kompleks model dan semakin banyak informasi yang dapat diproses. Namun, model dengan terlalu banyak layer dapat menyebabkan overfitting.
2. **Ukuran Layer (Ukuran Lapisan):** Ukuran layer menentukan jumlah neuron dalam setiap layer. Ukuran layer yang lebih besar

memungkinkan model untuk menangkap lebih banyak informasi, tetapi juga dapat meningkatkan risiko overfitting.

3. **Jenis Aktivasi (Jenis Fungsi Aktivasi):** Fungsi aktivasi menentukan bagaimana neuron dalam layer memproses informasi. Fungsi aktivasi yang berbeda menghasilkan output yang berbeda, dan pemilihan fungsi aktivasi yang tepat dapat meningkatkan performa model.
4. **Jenis Pooling (Jenis Penggabungan):** Operasi pooling digunakan untuk mengurangi dimensi data dalam layer tertentu. Jenis pooling yang berbeda memiliki efek yang berbeda pada data, dan pemilihan jenis pooling yang tepat dapat membantu model fokus pada informasi yang penting dan mengurangi overfitting.
5. **Jenis Konvolusi:** Overfitting merupakan masalah umum dalam pembelajaran mesin, di mana model menjadi terlalu spesifik pada data latih sehingga gagal memprediksi data baru dengan akurat. Dalam proses pelatihan model menggunakan data latih, penting untuk melakukan iterasi yang cukup agar model dapat memperbarui dirinya dan belajar dari data tersebut. Di PT JAYATAM SAFETINDO, penggunaan *deep learning* dengan *TensorFlow* untuk mendeteksi pakaian *safety* memerlukan pemantauan kinerja model secara berkala untuk memastikan bahwa model telah dilatih dengan cukup. Teknik regularisasi dan validasi silang adalah dua metode yang efektif untuk menghindari overfitting. Regularisasi membantu membatasi

kompleksitas model, sedangkan validasi silang memungkinkan pemilihan parameter pelatihan yang paling sesuai.

Dalam kasus PT JAYATAM SAFETINDO, beberapa faktor kunci dalam pelatihan model termasuk kualitas dan ukuran data pelatihan. Data yang berkualitas dan representatif akan memperkuat kemampuan model untuk mengenali berbagai kategori pakaian *safety*. Ukuran data yang memadai juga penting agar model dapat belajar secara efektif. Selain itu, pemilihan parameter pelatihan yang tepat, seperti jumlah lapisan, ukuran lapisan, jenis aktivasi, pooling, dan konvolusi, akan berkontribusi pada peningkatan kinerja model. Namun, perlu diingat bahwa penyesuaian parameter harus dilakukan dengan hati-hati untuk menghindari overfitting. Menggunakan data latih yang cukup, menerapkan regularisasi, dan melakukan validasi silang adalah langkah-langkah yang dapat diambil untuk mencegah overfitting dan memastikan model dapat menggeneralisasi dengan baik ke data baru.

2.2.7 Validasi Model

Validasi model merupakan langkah penting dalam *deep learning* untuk memastikan model yang dilatih memiliki kemampuan generalisasi yang baik. Dalam konteks deteksi pakaian *safety* menggunakan *TensorFlow* di PT JAYATAMA SAFETINDO, proses validasi dilakukan dengan memanfaatkan *Convolutional Neural Network* (CNN) pada dataset yang tidak digunakan selama pelatihan, dikenal sebagai set validasi. Teachable Machine secara otomatis melakukan validasi menggunakan set uji yang dipilih, dan hasil validasi dapat

dilihat di dashboard Teachable Machine. Metrik seperti akurasi, presisi, dan recall dapat digunakan untuk mengukur kinerja model dalam mendeteksi kualitas material pakaian *safety*.

2.2.8 Optimasi Model

Model yang optimal adalah kunci untuk performa deteksi yang mumpuni. Optimasi model dapat dilakukan dengan berbagai cara, seperti mengatasi overfitting dan underfitting, serta mengoptimalkan hyperparameter. Overfitting terjadi ketika model terlalu "terikat" pada data pelatihan dan tidak mampu beradaptasi dengan data baru. Hal ini dapat dicegah dengan menyederhanakan model atau memperbanyak data pelatihan yang representatif. Sebaliknya, underfitting terjadi ketika model gagal mempelajari pola data pelatihan, sehingga menghasilkan performa yang buruk. Solusi untuk underfitting adalah dengan memperumit model atau menambah jumlah data pelatihan. Hyperparameter, parameter yang diatur oleh pengguna, juga berperan penting dalam optimasi model. Menemukan nilai hyperparameter yang optimal dapat dilakukan melalui proses iteratif, mencoba berbagai nilai dan mengevaluasi hasilnya. Dengan menerapkan langkah-langkah optimasi model ini, perusahaan seperti PT JAYATAMA SAFETINDO dapat meningkatkan akurasi deteksi pakaian *safety*, memastikan keamanan dan kepatuhan terhadap peraturan.

2.2.9 Implementasi Model

Implementasi model merupakan langkah krusial dalam mewujudkan manfaat model yang telah dikembangkan. Proses ini melibatkan integrasi model dengan sistem yang telah ada, memastikan kelancaran dan kesesuaian model dengan infrastruktur dan alur kerja yang berjalan. Penyesuaian model dan sistem yang cermat menjadi kunci keberhasilan implementasi. Hal ini dapat dilakukan dengan berbagai cara, seperti penyesuaian API, modifikasi antarmuka, atau pengembangan komponen baru yang kompatibel. Dengan penerapan model yang tepat, sistem yang ada dapat diperkaya dengan kemampuan baru, meningkatkan efisiensi, dan memberikan nilai tambah bagi penggunanya.

2.2.10 Pemeliharaan Dan Pemantauan

Model yang optimal tidak hanya sebatas pada pengembangannya, melainkan juga dalam pemeliharaan dan pemantauan berkelanjutan. Hal ini penting untuk memastikan model tetap berfungsi dengan baik dan memberikan hasil yang akurat dalam mendeteksi pakaian *safety* di PT JAYATAMA SAFETINDO.

Pemeliharaan model merupakan proses yang berkelanjutan untuk menjaga model tetap up-to-date dan relevan. Hal ini dapat dilakukan dengan berbagai cara, seperti:

1. **Memperbarui model dengan data baru:** Data baru yang relevan dapat digunakan untuk meningkatkan kinerja model dan memastikannya tetap mampu beradaptasi dengan perubahan lingkungan.

2. Mengadopsi algoritme baru: Algoritma baru yang lebih canggih dapat diimplementasikan untuk meningkatkan akurasi dan kecepatan deteksi.
3. Melakukan perbaikan: Perbaikan pada model dilakukan untuk mengatasi masalah yang ditemukan, seperti bias atau anomali dalam hasil deteksi.

Pemantauan kinerja model merupakan proses penting untuk menilai performanya secara berkala. Hal ini dapat dilakukan dengan:

1. Evaluasi model pada set uji: Evaluasi terhadap data independen dapat memberikan gambaran objektif tentang kemampuan model dalam mendeteksi pakaian *safety* secara akurat.
2. Analisis hasil deteksi: Analisis hasil deteksi model dapat membantu mengidentifikasi potensi masalah dan area yang perlu diperbaiki.

Berikut adalah beberapa langkah penting dalam pemeliharaan dan pemantauan model untuk PT JAYATAMA SAFETINDO:

1. Pastikan model memiliki kinerja yang baik sebelum diimplementasikan: Lakukan evaluasi menyeluruh terhadap model sebelum digunakan dalam sistem operasional.
2. Rutin lakukan pemeliharaan model: Jadwalkan pemeliharaan model secara berkala untuk memastikannya tetap up-to-date dan relevan.
3. Pantau kinerja model secara berkala: Lakukan evaluasi dan analisis hasil deteksi secara berkala untuk mengidentifikasi dan mengatasi potensi masalah.

Dengan menerapkan pemeliharaan dan pemantauan model yang efektif, PT JAYATAMA SAFETINDO dapat memastikan bahwa model deteksi pakaian *safety* mereka selalu berfungsi dengan optimal, meningkatkan akurasi dan efisiensi dalam memastikan keamanan dan kepatuhan terhadap peraturan.

2.2.11 Pelatihan Penggunaan

Pelatihan pengguna merupakan elemen penting dalam memastikan pemanfaatan sistem deteksi pakaian *safety* secara optimal. Melalui pelatihan yang tepat, pengguna akan dibekali dengan pengetahuan dan keterampilan yang diperlukan untuk mengoperasikan sistem dengan aman dan efektif.

Berikut beberapa jenis pelatihan yang dapat diimplementasikan:

1. **Pelatihan Teoritis:** Tahap awal ini bertujuan untuk memperkenalkan pengguna kepada konsep-konsep dasar *deep learning* dan deteksi pakaian *safety*. Hal ini dapat dilakukan melalui presentasi, diskusi, atau materi pembelajaran mandiri.
2. **Pelatihan Praktis:** Pada tahap ini, pengguna akan mendapatkan kesempatan untuk belajar secara langsung bagaimana menggunakan sistem. Pelatihan praktik dapat mencakup:
 - a. **Demonstrasi dari Instruktur:** Instruktur akan mendemonstrasikan cara menggunakan sistem, menjelaskan fungsi-fungsi utama, dan memberikan contoh penerapannya.

- b. Latihan Mandiri: Pengguna akan diberikan kesempatan untuk mencoba menggunakan sistem secara mandiri dengan panduan instruksi yang jelas.
- c. Latihan dengan Bimbingan: Pengguna akan berlatih menggunakan sistem dengan bimbingan dan arahan langsung dari instruktur. Hal ini memungkinkan pengguna untuk mendapatkan umpan balik dan koreksi secara real-time.

Jenis dan durasi pelatihan dapat disesuaikan dengan kebutuhan dan tingkat keahlian pengguna. Dengan pelatihan yang komprehensif, pengguna akan siap untuk memanfaatkan sistem deteksi pakaian *safety* secara maksimal, meningkatkan akurasi dan efisiensi dalam memastikan keamanan dan kepatuhan terhadap peraturan.

2.2.12 Evaluasi Dan Perbaikan

Evaluasi dan perbaikan model merupakan proses berkelanjutan yang penting untuk memastikan kinerja optimal sistem deteksi pakaian *safety* di PT JAYATAMA SAFETINDO. Melalui evaluasi dan perbaikan yang cermat, akurasi dan efisiensi sistem dapat terus ditingkatkan, memastikan keamanan dan kepatuhan terhadap peraturan.

Berikut beberapa langkah yang dapat dilakukan dalam evaluasi dan perbaikan model:

1. Evaluasi Kinerja Model Secara Berkala: Kinerja model harus dievaluasi secara berkala menggunakan metrik-metrik seperti akurasi,

presisi, recall, dan F1-score. Hal ini membantu mengidentifikasi area yang perlu diperbaiki dan memantau kemajuan model seiring waktu.

2. **Analisis Hasil Deteksi:** Analisis hasil deteksi model dapat membantu mengidentifikasi masalah yang dapat memengaruhi kinerja, seperti bias, anomali, atau false positive. Hasil analisis ini menjadi dasar untuk melakukan penyesuaian model yang tepat.
3. **Lakukan Penyesuaian Model:** Penyesuaian model dapat dilakukan dengan berbagai teknik, seperti:
 - a. **Menambahkan data pelatihan baru:** Data pelatihan terbaru yang relevan dapat digunakan untuk meningkatkan kinerja model, terutama dalam mengidentifikasi pola dan tren terbaru.
 - b. **Menyesuaikan hyperparameter:** Hyperparameter model dapat dioptimalkan untuk mencapai keseimbangan terbaik antara akurasi dan efisiensi.
 - c. **Menggunakan teknik transfer learning:** Teknik transfer learning dapat dimanfaatkan untuk meningkatkan kinerja model pada dataset yang kecil dengan menggunakan pengetahuan dari model lain yang telah dilatih pada dataset yang lebih besar.

Hal-hal yang perlu diperhatikan dalam evaluasi dan perbaikan model deteksi pakaian *safety* di PT JAYATAMA SAFETINDO: Gunakan data pelatihan terbaru, Pastikan data pelatihan yang digunakan selalu diperbarui dengan data terbaru untuk mencerminkan kondisi terkini dan meningkatkan akurasi model. Pertimbangkan penggunaan teknik transfer learning: Teknik transfer learning dapat membantu

meningkatkan kinerja model pada dataset yang relatif kecil, seperti dataset pakaian *safety* di PT JAYATAMA SAFETINDO. Dengan menerapkan evaluasi dan perbaikan model secara konsisten dan efektif, PT JAYATAMA SAFETINDO dapat memastikan sistem deteksi pakaian *safety* mereka selalu berfungsi dengan optimal, meningkatkan keamanan dan kepatuhan di lingkungan kerja.

2.3 Hipotesis Penelitian

Deep learning dengan *TensorFlow* menawarkan solusi efektif untuk mendeteksi kualitas pakaian *safety* dengan akurasi tinggi. Hal ini dimungkinkan karena penggunaan metode *Convolutional Neural Network* (CNN) yang terbukti handal dalam berbagai tugas pengenalan pola dan klasifikasi, termasuk mendeteksi pakaian *safety* dan tidak *safety*. *TensorFlow*, sebagai *Framework deep learning* yang populer dan mudah digunakan, menyediakan platform yang ideal untuk membangun model deep learning yang akurat untuk deteksi kualitas gambar dari berpakaian *safety* dan tidak berpakaian *safety*. Kemampuannya dalam memproses data gambar yang kompleks dan mengidentifikasi pola secara detail menjadikan *TensorFlow* alat yang tepat untuk menunjang sistem deteksi ini.

2.3 Penelitian terdahulu

Banyak penelitian telah dilakukan untuk mendeteksi kualitas material dengan memanfaatkan deep learning. Beberapa di antaranya adalah:

1. “Deep learning for pockmark detection” oleh MA Lundine et al. (2023):
Penelitian ini menggunakan deep learning untuk mendeteksi cacat

pockmark pada permukaan material, mencapai akurasi sebesar 98%. Artikel ini dapat diakses di ScienceDirect.

2. “Comparative Study on Distributed Lightweight Deep Learning for Intelligent Traffic Systems” oleh H Tahir et al. (2023): Penelitian ini berfokus pada penerapan deep learning untuk mendeteksi objek dalam gambar dengan akurasi tinggi, terutama dalam konteks sistem transportasi cerdas dan mobil swakemudi. Artikel lengkapnya tersedia di MDPI.
3. “A New Approach Based on TensorFlow Deep Neural Networks and Geographic Information Systems for Predicting Landslide Susceptibility” oleh TX Truong et al. (2023): Penelitian ini menggabungkan deep learning dengan sistem informasi geografis (GIS) untuk memprediksi kerentanan tanah longsor, dengan akurasi mencapai 95%. Temuan lengkapnya dapat dibaca di MDPI.
4. “Analisis Implementasi Quality Control pada Produksi Gula di PT PERKEBUNAN NUSANTARA (XIV) PERSERO” oleh Jumriani. Penelitian ini menunjukkan aplikasi deep learning dalam pengendalian kualitas produksi gula, dengan fokus pada efektivitas deteksi cacat material. Penelitian-penelitian tersebut menunjukkan bahwa deep learning dapat digunakan secara efektif untuk mendeteksi kualitas material dengan akurasi yang tinggi. Teknologi ini mampu menganalisis data gambar dan video untuk mengidentifikasi pola dan cacat yang mungkin tidak terlihat oleh mata manusia.