

BAB II

TINJAUAN PUSTAKA

2.1 Tinjauan Teori

2.1.1 Tinjauan Teori Umum

2.1.1.1 *Incoming quality control (IQC)*

Incoming Quality Control atau *IQC* adalah sebuah proses pada dasarnya dilibatkan menjadi lembaga penilaian kualitas dari segala sesuatu yang terlibat dalam proses *materials*. Yang merupakan bagian penting untuk mengurangi biaya, meningkatkan kualitas *material* akhir. Pemeriksaan kualitas adalah proses yang sangat penting untuk memastikan *material* sesuai dengan standar yang telah ditentukan. (Sarivan et al. 2020).

Incoming quality control adalah proses yang sangat penting untuk memastikan bahwa *material* siap digunakan dalam *materials* dan memegang peran penting untuk memastikan *material* yang akan masuk ke dalam proses *materials*. Pemeriksaan *material* yang sesuai standar yang dilakukan selama proses pemeriksaan *material* adalah untuk mendeteksi kualitas akhir *material*. Dalam hal ini sangat penting untuk mendeteksi sejak awal dengan tidak menerima *material* yang tidak bagus. (Sarivan et al. 2020).

IQC melakukan Acceptance Sampling yaitu pengambilan sampel inspeksi untuk menentukan kesesuaian kualitas *material* dengan spesifikasi yang ditentukan dengan memeriksa sampel dari kedatangan *material*. Pengambilan sampel dilakukan untuk memantau dan meningkatkan kualitas *material*. Salah satu manfaat Acceptance Sampling adalah untuk meningkatkan kualitas *material* jadinya. Acceptance Sampling datanya diperoleh dari pengamatan kesesuaian kualitas sesuai dengan standar yang telah

ditetapkan. Ada teknik pengambilan sampel yang berbeda berdasarkan jumlah sampel yang diambil untuk menentukan lolos atau tidak lolosnya suatu *material* yang datang. Proses desain sampel tunggal menentukan apakah akan menerima atau menolak suatu batch berdasarkan informasi dari n sampel yang diambil secara acak dari suatu batch *material*. Informasi banyaknya *material* yang tidak memenuhi spesifikasi (d) dari hasil pemeriksaan menjadi dasar pengambilan keputusan. Jika $d \leq c$ maka lot diterima, jika $d > c$ maka lot ditolak. Probabilitas penerimaan (P_a) dalam desain pengambilan sampel tunggal dapat dihitung dengan menggunakan rumus pada Persamaan. (Salwa and Mashuri 2021).

$$P_a = P(d \leq c) = \sum_{d=0}^c \frac{n!}{d!(n-d)!} p^d (1-p)^{n-d}$$

Keterangan

P_a = probabilitas penerimaan lot

C = batas penerimaan produk cacat

Istilah Acceptable Quality Level (AQL) adalah nilai sebesar yang merupakan persentase maksimum *material* cacat yang rata-rata proses dapat ditoleransi oleh konsumen sebesar . Toleransi Lot Persentase Cacat (LTPD) adalah batas maksimum yang dapat diterima konsumen untuk persentase *material* cacat dalam lot. Nilai LTPD biasanya diperoleh dari kesepakatan antara produsen dan konsumen. Nilai risiko dapat dirumuskan. β

$$1 - \alpha = \sum_{d=0}^c \frac{n!}{d!(n-d)!} p_1^d (1 - p_1)^{n-d}$$

$$\beta = \sum_{d=0}^c \frac{n!}{d!(n-d)!} p_2^d (1 - p_1)^{n-d}$$

Keterangan :

P_1 = AQL (Acceptable Quality Level)

P_2 = LTPD (Lot Tolerance Percent Defective)

Tahapan *IQC* merupakan proses pemeriksaan atau pengendalian kualitas bahan baku yang diperoleh dari pemasok. Jumlah *material* yang diperiksa dan penentuan lulus atau gagal untuk lot mengacu pada II-Single Sampling Plan Military Stdird 105E level jenis inspeksi normal. Setiap batch bahan yang masuk diambil sampelnya sebanyak dan keputusan dibuat untuk menerima atau menolak batch berdasarkan kriteria yang ditetapkan.(Salwa and Mashuri 2021).

Ruang lingkup pemeriksaan meliputi pemeriksaan *material*. Inspeksi *material* melibatkan pemeriksaan visual setiap *material*, biasanya menggunakan mikroskop stereo, untuk mendapatkan rincian rinci sebelum menjual *material* ke pasar luar. Pemeriksa menerima daftar dan deskripsi cacat *material* cacat yang tidak dapat diterima (tidak dapat dilepas), seperti retak dan cacat permukaan. Jika salah satu dari ketiga aspek tersebut tidak terpenuhi maka kualitas hasil akan terancam. Fokus pengendalian kualitas adalah memeriksa *material* untuk menemukan *material* cacat atau *NG*. Saat memilih *material* untuk diuji, pemilihan *material* biasanya dilakukan secara acak (menggunakan metode sampling). Setelah memastikan *material* cacat, kami memberi tahu pengambil keputusan manajemen apakah *material* tersebut dapat diterima atau tidak. Hal ini untuk penjaminan mutu, upaya untuk memperbaiki dan menstabilkan proses *materials* (dan proses terkait lainnya) untuk menghindari, atau setidaknya meminimalkan, permasalahan yang menyebabkan terjadinya cacat, yaitu

permasalahan pabrik. Dalam pekerjaan kontrak, khususnya pekerjaan pemerintah, masalah pengendalian kualitas menjadi salah satu alasan utama mengapa kontrak kerja tidak diperpanjang. Di bawah ini adalah definisi pengendalian mutu dari tiga ahli yang berbeda. (Ilham Ramdhani et al. 2022)

1. Menurut Nur Fitlihana, pengertian pengendalian mutu atau incoming quality control mencakup segala upaya untuk menjamin bahwa hasil pelaksanaannya sesuai dengan rencana yang telah ditentukan dan akan terlihat oleh konsumen (pelanggan)puas.
2. Pengendalian kualitas (*IQC*) mengidentifikasi komponen mana yang rusak dan memastikan bahwa bahan yang digunakan dalam produksi di masa depan masih utuh. Pengendalian mutu merupakan suatu alat manajemen untuk meningkatkan mutu produk, mempertahankan mutu yang tinggi dan mengurangi jumlah bahan yang rusak jika diperlukan
3. Kualitas secara umum berarti membuat suatu produk atau jasa tepat waktu dan sesuai untuk digunakan di lingkungan, tanpa cacat dan tanpa mengecewakan konsumen.(Ilham Ramdhani et al. 2022).

Definisi Kualitas secara umum, kualitas dapat diartikan sebagai merujuk pada satu atau lebih karakteristik yang ada pada suatu barang atau jasa tertentu). Ada tiga jenis atribut kualitas: fisik (misalnya panjang, berat), sensorik (misalnya rasa, warna), dan temporal (misalnya umur simpan, yaitu berapa lama produk akan digunakan). Delapan dimensi kualitas adalah kinerja, kedilan, daya tahan, kemudahan penggunaan, estetika, fungsionalitas, kualitas yang dirasakan, dan kriteria kesesuaian. Kualitas dapat dibagi menjadi dua kategori: kualitas produk

dan kualitas proses. Tingkat kualitas desain produk tergantung pada segmen pasar yang ingin dijangkau, namun tujuannya harus berdasarkan permintaan konsumen (customer requiremen). Tujuan dari kualitas proses adalah agar perusahaan dapat menghasilkan produk dan proses jasa yang sempurna (produk bebas cacat) dengan menerapkan manajemen kualitas total.(Ilham Ramdhani et al. 2022).

Material back cover dalam IQC

Material back cover terbuat dari plastik yang digunakan untuk membuat produk jadi. Pada dasarnya pengertian dari *back cover* adalah bagian penutup yang menutupi barang – barang kecil seperti pcb dan lain – lain. Kontribusi *Material back cover* terhadap Kualitas Produk Akhir:

1. Estetika : *back cover* dapat memberikan tampilan produk jadi dan menciptakan persepsi kualitas
2. Ketahanan : kualitas *back cover* berpengaruh pada ketahanan produk akhir terhadap penggunaan sehari – hari dan faktor lingkungan.
3. Kesesuaian : *back cover* harus sesuai dengan persyaratan fungsional dan desain produk secara keseluruhan.

IQC memastikan bahwa *back cover* yang akan digunakan dalam proses produksi memiliki ketepatan yang diperlukan. Proses ini membantu mencegah *back cover* yang NG dalam produksi, mengurangi resiko *material NG* (Ilham Ramdhani et al. 2022).

2.1.1.2 Deteksi Kualitas *Material Back cover*

Deteksi kualitas *material* adalah tahap awal dari penggunaan *image processing* atau pengelolaan citra merupakan teknik yang digunakan untuk

memanipulasi atau menganalisis gambar dan mendapatkan informasi yang berharga dari gambar tersebut. Dalam konteks deteksi kualitas *material back cover* dapat digunakan untuk mengevaluasi, menganalisis, dan mengidentifikasi sifat-sifat *material back cover* dalam citra atau gambar.

2.1.2 Tinjauan Teori Khusus

2.1.2.1 Pengolahan Citra

2.1.2.1.1 Defenisi Citra

Citra adalah representasi visual dua dimensi dari objek atau adegan yang direkam dalam bentuk visual atau gambar. Citra terbentuk oleh kumpulan elemen kecil yang disebut *piksel*, yang memiliki nilai-nilai intensitas atau warna tertentu. Citra dapat mewakili berbagai jenis informasi visual, termasuk gambar fotografi, grafik computerized, atau hasil pemindaian dari dokumen fisik. Citra dapat dihasilkan oleh berbagai perangkat dan proses, seperti kamera advanced, pemindai (scanner), atau penciptaan grafis komputer. Jenis citra dapat bervariasi, mencakup citra hitam-putih (grayscale) yang hanya memiliki tingkat keabuan, dan citra berwarna yang mencakup kombinasi warna tertentu pada setiap *piksel*. Pengolahan citra advanced melibatkan berbagai teknik untuk meningkatkan, menganalisis, atau memanipulasi citra dengan menggunakan perangkat lunak khusus. Citra juga dapat digunakan dalam berbagai bidang seperti pengolahan gambar medis, visi komputer, grafika komputer, dan berbagai aplikasi lainnya yang melibatkan analisis atau representasi visual. (Caggiano et al. 2019)

2.1.2.1.2 Defenisi Citra Digital

Citra digital merupakan gambar yang tersimpan dalam format digital (dalam bentuk file). Hanya citra yang berbentuk digital yang dapat diolah menggunakan

komputer. Jenis citra lainnya, jika akan diproses dengan komputer, harus diubah terlebih dahulu menjadi citra digital. Pencitraan adalah proses mengubah informasi dari citra tampak atau citra non-digital menjadi citra digital. Beberapa perangkat yang dapat digunakan untuk pencitraan melibatkan scanner, kamera digital, kamera sinar-X atau sinar inframerah, dan sejenisnya. Pengolahan citra merujuk pada aktivitas meningkatkan kualitas citra agar lebih mudah diinterpretasikan oleh manusia. Berbagai teknik pengolahan citra mampu mentransformasikan citra dari satu bentuk ke bentuk lainnya. Citra digital menjadi input dalam proses pengolahan citra.

2.1.2.2 *Computer Vision*

Computer vision adalah suatu teknologi yang memungkinkan komputer untuk memahami, mengelompokkan, dan memproses citra. Tujuan utama dari *computer vision* adalah mengajarkan komputer untuk memahami dan menginterpretasi information visual, seperti gambar dan video. *Computer vision* beroperasi dengan memanfaatkan algoritma dan teknologi *deep learning* untuk mengidentifikasi dan menganalisis fitur-fitur dalam citra atau video, seperti bentuk, warna, dan tekstur. Sistem komputer kemudian melakukan pengelompokan dan pemrosesan data visual untuk memberikan dukungan dalam pemahaman dan interpretasi citra atau video bagi manusia. Dengan mengintegrasikan kecerdasan buatan, *computer vision* memungkinkan komputer untuk secara otomatis mengenali pola, objek, dan konteks visual, memberikan kontribusi penting dalam berbagai aplikasi, mulai dari pengenalan objek hingga analisis visual yang kompleks.

2.1.2.3 Artificial Intelligence

Artificial Intelligence (AI) adalah teknologi yang memungkinkan komputer untuk melakukan tugas yang biasanya hanya dapat dilakukan oleh manusia, seperti pemahaman, pembelajaran, dan pemrosesan data. Kecerdasan buatan (AI) menggunakan algoritma dan teknologi seperti *Machine learning*, *deep learning*, dan *natural language processing* untuk menciptakan program yang mampu mengambil keputusan, memahami bahasa, serta melaksanakan tugas tanpa keterlibatan manusia. AI memiliki beragam aplikasi, seperti pengenalan deteksi objek, pengenalan tulisan tangan, dan pemrosesan citra medis. Dengan mengintegrasikan big data dan ilmu komputer, AI memiliki kapabilitas untuk menghasilkan output yang diinginkan. Penerapan AI dapat memberikan kontribusi signifikan terhadap peningkatan efisiensi dan produktivitas di berbagai sektor, termasuk industri, kesehatan, dan keuangan. (Nasional and Tro 2023)

2.1.2.4 Machine learning

Machine learning merupakan teknologi yang memungkinkan komputer untuk belajar dari data dan mengambil keputusan berdasarkan pola yang teridentifikasi dalam data tersebut. *Machine learning* digunakan untuk menganalisis data historis dan meramalkan di masa mendatang. Berbagai jenis *Machine learning*, termasuk regresi linier, decision tree, dan *neural network*, digunakan untuk meramalkan. Penerapan *Machine learning* ini dapat memberikan prediksi yang lebih akurat, dengan dampak positif pada efisiensi energi dan pengurangan biaya operasional. *Machine learning* bekerja dengan mengolah data historis, sehingga mampu meramalkan hasil yang lebih tepat dari input data yang

diberikan. Proses ini memungkinkan pengambilan keputusan dan prediksi yang lebih akurat berdasarkan data yang telah dianalisis. Selain itu, *Machine learning* berkontribusi dalam meningkatkan efisiensi dan produktivitas di berbagai sektor, termasuk industri, kesehatan, dan keuangan.(Zhang et al. 2021).

2.1.2.5 Deep learning


Deep learning merupakan cabang dari *Machine learning* yang memanfaatkan *neural network* dengan banyak lapisan, dikenal sebagai *deep neural network*, untuk menginterpretasi dan mengolah data. Penggunaan teknologi *Machine learning* dalam memprediksi beban bangunan dapat melibatkan pendekatan *deep learning*, di mana algoritma ini mampu memproses dan memahami pola-pola yang kompleks dalam data, terutama melalui struktur hierarkis lapisan-lapisan *neural network*. Dengan demikian, *deep learning* dapat memberikan kontribusi dalam meningkatkan ketepatan dan akurasi prediksi terkait. Beberapa struktur *deep learning* yang sering digunakan untuk keperluan deteksi menggunakan *Convolutional neural network (CNN)*. *Deep learning* melibatkan penggunaan contoh dari data latihan untuk melatih komputer, memodifikasi jaringan saraf, dan menyesuaikan rutennya, memungkinkan mesin menerima masukan baru dan menghasilkan keluaran. Teknologi ini diterapkan dalam berbagai skenario dunia nyata, termasuk filter spam di layanan email seperti Gmail dan Yahoo, asisten virtual seperti Alexa dari Amazon, serta rekomendasi konten di YouTube yang didasarkan pada preferensi sebelumnya. Perusahaan seperti Tesla, Apple, dan Nissan mempergunakan teknologi ini untuk mengembangkan sistem otonom. *Deep learning* adalah salah satu metode dalam bidang pembelajaran mesin. Ldisan dari *deep learning* adalah dalam meniru

struktur neuron otak manusia menggunakan neuron buatan, atau perceptron. Perceptron ini bekerja dengan menerima input dengan bobot yang diberikan pada setiap input, kemudian melakukan komputasi untuk menghasilkan output. Neuron akan memberikan penekanan yang berbeda pada input berdasarkan bobotnya, memungkinkan penyesuaian model-data yang optimal. Fungsi aktivasi memainkan peran penting dalam transformasi input menjadi output, seperti ambang batas atau transformasi linier. Jaringan saraf menggunakan banyak perceptron yang tergabung dalam lapisan-lapisan dengan fungsi aktivasi yang berbeda. Jika terdapat lebih dari dua lapisan dalam jaringan saraf, ini disebut sebagai model pembelajaran mendalam. Lapisan-lapisan ini membantu meningkatkan akurasi model dengan memodelkan pola tingkat atas dalam data. Meskipun jaringan saraf meniru otak, kapasitas pemrosesannya tidak sebanding dengan otak manusia. Kekuatan utama jaringan saraf terletak pada latihannya dengan data besar, memungkinkannya untuk mengidentifikasi pola-pola yang kompleks. Dalam perkembangannya, *Deep learning* menggunakan jaringan berlapis-lapis yang besar untuk mengungkap struktur data yang lebih kompleks.(Chattopadhyay and Maitra 2022). Untuk melatih *deep learning* memerlukan sejumlah besar gambar dengan fitur berbeda untuk menghindari overfitting dan non-konvergensi. Pembesaran gambar dengan transformasi geometri terutama melibatkan pencerminan dan rotasi gambar. Pencerminan gambar mencakup cermin horizontal dan vertikal. Pencerminan gambar mencakup cermin horizontal dan vertikal. Cermin horizontal mengubah bagian kiri dan kanan bayangan terhadap garis vertikal bayangan. Pencerminan vertikal

mengubah bagian atas dan bawah gambar terhadap garis tengah horizontal gambar. Rotasi gambar memutar gambar masing-masing sebesar 90° , 180° , dan 270° . Proses pembelajaran melibatkan penyesuaian berulang pada bobot jaringan, mengecilkan kesenjangan antara hasil aktual dengan yang diharapkan. Lapisan-lapisan internal yang tidak langsung terhubung dengan input atau output, menjadi lebih penting setelah penyesuaian bobot. Hubungan antara tingkatan ini memastikan keteraturan dalam domain tugas tersebut. Model *deep learning* memiliki keunggulan dibandingkan dengan model machine learning tradisional karena menambah jumlah lapisan pembelajaran dan tingkat abstraksi yang lebih tinggi. Hal ini juga disebabkan oleh pembelajaran berbasis data langsung untuk semua komponen model. Model pembelajaran mesin tradisional memiliki keterbatasan karena algoritma yang mereka gunakan, terutama seiring dengan meningkatnya ukuran data dan permintaan akan wawasan yang memadai dari data. Dalam menghadapi perluasan data, telah terjadi pengembangan algoritma pembelajaran yang lebih canggih, cepat, dan akurat untuk menjaga keunggulan kompetitif dalam penggunaan model yang dapat memberikan prediksi yang paling akurat. (Zhou et al. 2020).

Model *deep learning* memiliki keunggulan dibandingkan dengan model machine learning tradisional karena menambah jumlah lapisan pembelajaran dan tingkat abstraksi yang lebih tinggi. Hal ini juga disebabkan oleh pembelajaran berbasis data langsung untuk semua komponen model. Model pembelajaran mesin tradisional memiliki keterbatasan karena algoritma yang mereka gunakan, terutama seiring dengan meningkatnya ukuran data dan permintaan akan wawasan

yang memadai dari data. Dalam menghadapi perluasan data, telah terjadi pengembangan algoritma pembelajaran yang lebih canggih, cepat, dan akurat untuk menjaga keunggulan kompetitif dalam penggunaan model yang dapat memberikan prediksi yang paling akurat. (Chattopadhyay and Maitra 2022)




Gambar 2. 1 Konsep *Deep learning*

2.1.2.6 *Convolutional neural network*

Convolutional Neural Network (*CNN*) adalah jenis model *deep learning* yang biasa digunakan untuk pemrosesan dan analisis gambar. *CNN* digunakan untuk memproses dan mendeteksi menggunakan gambar. *CNN* sangat efektif dalam tugas-tugas pengenalan pola visual dan memahami hierarki fitur dalam data spasial. Berikut adalah penjelasan umum tentang *CNN* adalah *CNN* terdiri dari lapisan-lapisan *konvolusi* yang bertugas untuk mengekstrak fitur dari data input. Lapisan ini umumnya terdiri dari *konvolusi*, *pooling* (subsampling), dan fungsi aktivasi, Lapisan *konvolusi* menggunakan filter atau *kernel* untuk melakukan operasi *konvolusi* pada input. Operasi ini menghasilkan peta fitur, di mana setiap elemen mewakili respons terhadap fitur tertentu dalam data, Lapisan *pooling* 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, Fungsi aktivasi, seperti *RELU*

(Rectified Linear Unit), diterapkan untuk memperkenalkan non-linearitas ke dalam model. Ini memungkinkan model untuk mempelajari hubungan yang lebih kompleks dan meningkatkan kemampuan untuk menangkap pola yang rumit, Setelah serangkaian lapisan *konvolusi* dan *pooling*, hasilnya dikonversi menjadi vektor dan diteruskan ke lapisan *fully connected* untuk klasifikasi atau tugas lainnya, *CNN* diperoleh melalui proses pelatihan yang melibatkan penyesuaian bobot dan bias menggunakan metode *backpropagation*. Gradien *loss* dihitung dan digunakan untuk mengoptimalkan parameter-model, *CNN* banyak digunakan dalam berbagai tugas seperti pengenalan objek, klasifikasi citra, deteksi, segmentasi objek, dan tugas-tugas lain yang melibatkan data visual. *CNN* memanfaatkan struktur spasial data dan memiliki kemampuan untuk memahami pola hierarkis dalam citra. Hal ini membuatnya sangat efektif dalam tugas-tugas pengolahan citra dan pengenalan pola visual.(Chattopadhyay and Maitra 2022).



Gambar 2. 2 Tahapan Algoritma Convolution

2.2.1.7 Python

Python, yang diciptakan oleh Guido Van Rossum, merupakan salah satu bahasa pemrograman yang mudah dipahami dan serbaguna. Digunakan untuk pembuatan aplikasi, memberikan perintah komputer, dan melakukan analisis data,

Python semakin populer dan berkembang pesat. Bahasa pemrograman ini digunakan dalam berbagai konteks, termasuk pengembangan kecerdasan buatan, analisis data, dan pembuatan aplikasi. Dengan filosofi yang menekankan keterbacaan kode dan kesederhanaan sintaks, Python menjadi pilihan utama bagi pengembang dari berbagai tingkat keahlian, mulai dari pemula hingga ahli. Sintaksis yang sederhana dan mudah dipahami juga membuat Python menarik bagi banyak orang yang ingin mempelajarinya.

2.1.1.8 *Tensorflow*

Tensorflow adalah platform machine learning yang open source yang memanfaatkan sumber daya komputasi heterogen seperti CPU, GPU dan TPU untuk mengembangkan model dan melatih data dengan cepat. *Tensorflow* menyediakan serangkaian fungsi dan kelas yang memungkinkan pengguna membuat model sapa yang kompleks. Versi terbarunya adalah tensorflow 2.15 yang mengalami peningkatan signifikan dibandingkan versi sebelumnya. *Tensorflow* dengan cepat diadopsi secara luas di komunitas *deep learning* karena kemudahan penggunaannya untuk menerapkan model ke browser web dan perangkat seluler. *Tensorflow* dapat digunakan untuk mengembangkan tugas non-dl yang memerlukan komputasi numerik menggunakan grafik aliran data. (Parisi et al. 2021).

Model *tensorflow* dapat dieksekusi untuk pertama paradigma komputasi *deep learning*. Sistem runtime *tensorflow* menggunakan parameter yang dipelajari selama fase pelatihan untuk menafsirkan dan mengeksekusi grafik komputasi. (Parisi et al. 2021)

Selama fase pelatihan, waktu yang diperlukan untuk memperoleh pengetahuan dalam bentuk model bergantung pada pemilihan fungsi *Tensorflow* API dan parameter yang dipilih untuk setiap eksperimen. Bagian ini menggunakan fungsi API yang lebih tinggi yang dapat digunakan untuk pengembangan model, serta berbagai parameter khusus yang digunakan untuk menyempurnakan keakuratan model. Model mempelajari dan menyimpan pengetahuan dalam bentuk parameter model. Parameter model adalah elemen internal model yang nilainya diperkirakan atau dipelajari dari data pelatihan. (Parisi et al. 2021)

Untuk menentukan kemampuan model untuk menentukan kemampuan model untuk memecahkan masalah dan menggunakannya untuk membuat prediksi. Ini disimpan sebagai bagian dari model yang dilatih. Model parameter diperkirakan menggunakan algoritma optimasi yang disediakan oleh *tensorflow* dalam bentuk fungsi API (Parisi et al. 2021)

Tensorflow memiliki beberapa fitur utama yang membuatnya menjadi kerangka kerja pembelajaran mesin yang populer, antara lain:

1. **Fleksibilitas:** *Tensorflow* dapat digunakan untuk membangun berbagai macam model pembelajaran mesin, termasuk jaringan saraf tiruan, mesin vektor dukungan, dan pohon keputusan
2. **Skalabilitas:** *Tensorflow* dapat digunakan untuk melatih model pembelajaran mesin pada kumpulan data yang besar, baik di CPU maupun GPU.

3. Efisiensi: *Tensorflow* menggunakan berbagai teknik optimasi untuk mempercepat pelatihan model pembelajaran mesin.
4. Kemudahan Penggunaan: *Tensorflow* memiliki API yang mudah digunakan dan dilengkapi dengan berbagai dokumentasi dan tutorial.

Tensorflow memiliki arsitektur yang fleksibel dan modular yang memungkinkan pengguna untuk membangun model *deep learning* yang kompleks dengan mudah. *Tensorflow* menggunakan grafik komputasi untuk mewakili model *deep learning*. Grafik komputasi terdiri dari node dan edge. Node mewakili operasi matematika, seperti penjumlahan dan perkalian. Edge mewakili aliran data antara node. *Tensorflow* menggunakan tensor untuk mewakili data dalam grafik komputasi. Tensor adalah array multidimensi yang dapat berisi data numerik atau data kategorikal. (Maliar, Maliar, and Winant 2021).

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 *measurement* 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 *recall*, *precision* dan *accuracy*.

a. Recall adalah Recall adalah perbandingan yang benar antara prediksi positif dan keseluruhan data positif yang sebenarnya. Dalam konteks klasifikasi, recall memberikan jawaban untuk pertanyaan "Berapa persentase dari total data aktual yang berhasil diprediksi dengan benar oleh model?" Konsep ini bermanfaat dalam menilai kemampuan model untuk mengidentifikasi seluruh contoh yang seharusnya dianggap positif. Berikut adalah referensi matriks confusion yang menampilkan prediksi dan kondisi sebenarnya dari data yang dihasilkan oleh algoritma yang telah digunakan.

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

Tabel 2. 1 matriks confusion

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

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

$$\text{Recal} = \frac{\text{True positif(TP)}}{\text{True Positif(TP) + False Negatif(FN)}}$$

$$\text{True Positif(TP) + False Negatif(FN)}$$

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

$$\text{Precision} = \frac{\text{True positif (TP)}}{\text{True Positif (TP) + False Positif (FP)}}$$

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

b. Precision adalah Precision dalam konteks klasifikasi mengacu pada rasio prediksi positif yang benar dibandingkan dengan total data yang diprediksi sebagai positif oleh model. Dalam istilah klasifikasi, precision memberikan jawaban untuk pertanyaan seputar persentase data yang diprediksi sebagai positif oleh model yang memang benar-benar positif. Precision menjadi indikator yang berguna untuk menilai sejauh mana kemampuan model dalam mengidentifikasi contoh yang seharusnya positif dengan akurat.

c. Akurasi (Accuracy) adalah proporsi prediksi yang tepat (baik positif maupun negatif) dibandingkan dengan keseluruhan data. Dalam situasi klasifikasi, akurasi memberikan jawaban terhadap pertanyaan "Berapa persen data yang berhasil diprediksi dengan benar oleh model?" Akurasi bermanfaat untuk mengukur sejauh mana model dapat mengidentifikasi dengan tepat baik contoh positif maupun negatif. Rumus yang digunakan dalam accuracy adalah sebagai berikut:

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

2.2 Kerangka Pemikiran

2.2.1 Pemahaman Masalah

Beberapa masalah umum terkait kualitas visual *material* di departemen *IQC* melibatkan inspeksi dan evaluasi visual terhadap komponen atau *material* yang baru tiba. Beberapa masalah yang ingin dipecahkan:

1. Cacat permukaan : identifikasi dan kategorikan cacat-cacat permukaan pada *material* seperti goresan atau retak.
2. Kerusakan structural : identifikasi kerusakan structural atau cacat yang dapat mempengaruhi kekuatan atau kinerja *material* seperti patah.
3. Kebersihan dan kontaminasi : evaluasi tingkat kebersihan *material* dan deteksi adanya kontaminasi yang dapat mempengaruhi kualitas produk.
4. Kesesuaian labelling dan marking : memastikan label dan tdi – tdi pada *material* atau produk sesuai dengan spesifikasi yang ditetapkan.
5. Warna : evaluasi warna *material*

Dengan memahami dan mengidentifikasi masalah – masalah ini, departemen *iqc* dapat merancang sistem inspeksi visual yang efektif dengan menggunakan teknologi *deep learning* dan *tensorflow* untuk mendukung proses kontrol kualitas *material* secara otomatis dan efisien.

2.2.2 Pengumpulan Data

Pengumpulan data merupakan langkah penting dalam pengembangan model *deep learning* untuk mendeteksi kualitas *material* di departemen *iqc*. Berikut adalah beberapa langkah yang digunakan untuk mengumpulkan dataset.

1. Identifikasi kategori kualitas *material* : identifikasi jenis kualitas *material* yang perlu dideteksi seperti retak, warna, kebersihan dan kontaminasi.
2. Kerjasama dengan departemen *iqc* :kolaborasi dengan tim departemen *iqc* untuk memahami kriteria standar kualitas *material* yang mereka terapkan dan mendapatkan wawasan dari inspektur dan ahli kualitas mengenai ciri – ciri kualitas *material* yang relevan.
3. Penentuan jumlah dan variasi sampel : tentukan jumlah sampel yang cukup besar untuk setiap kategori kualitas 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 adalah proses mempersiapkan data untuk pelatihan model *deep learning*. Proses ini penting untuk memastikan data digunakan untuk pelatihan berkualitas baik dan dapat digunakan oleh model untuk belajar yang lebih efektif. *Preprocessing* data yang dilakukan meliputi :

1. *Data cleaning*, proses menghilangkan data yang tidak valid atau tidak diperlukan, seperti data yang kosong, data yang rusak, atau data yang tidak relevan dengan tujuan pelatihan.
2. *Data normalization*, yaitu proses mengubah nilai data agar berada dalam rentang yang sama. Hal ini penting untuk memastikan model dapat belajar dengan konsisten.

3. Data *augmentation*, yaitu proses membuat data baru dari data yang ada. Hal ini dilakukan untuk meningkatkan jumlah data pelatihan dan mengurangi *overfitting*.

2.2.4 Pemisahan Data

Pemisahan data adalah proses membagi data menjadi beberapa subset. Subset-subset ini kemudian digunakan untuk tujuan yang berbeda, seperti pelatihan, validasi, dan uji. Untuk mendeteksi kualitas *material* dengan *deep learning* menggunakan *Tensorflow* pada departemen *IQC*, data perlu dibagi menjadi tiga subset:

1. Set *train* digunakan untuk melatih model. Set *train* harus mencakup sebanyak mungkin data yang mewakili semua kategori kualitas.
2. Set tes digunakan untuk mengevaluasi kinerja model selama pelatihan. Set tes tidak boleh digunakan untuk melatih model.

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

2.2.5 Arsitektur Model

Arsitektur model adalah struktur dari model *deep learning*. Arsitektur model menentukan bagaimana data akan diproses oleh model. Untuk mendeteksi kualitas *material* dengan *deep learning* menggunakan *Tensorflow* pada departemen *IQC*, arsitektur model yang sesuai adalah *Convolutional neural network (CNN)*. *CNN* adalah arsitektur model yang dirancang untuk tugas deteksi visual. *CNN* bekerja

dengan mempelajari pola dalam data visual, seperti tepi, garis, dan bentuk. Pemilihan arsitektur model harus didasarkan pada kompleksitas masalah dan ukuran dataset. Untuk masalah yang kompleks, seperti deteksi kualitas *material*, diperlukan arsitektur model yang kompleks. Untuk ukuran dataset yang besar, diperlukan arsitektur model yang dapat menangani jumlah data yang besar.

2.2.6 Pelatihan Model

Pelatihan model adalah proses pembelajaran model menggunakan data pelatihan. Proses ini berlangsung selama beberapa iterasi, di mana model akan diperbarui berdasarkan data pelatihan. Untuk mendeteksi kualitas *material* dengan *deep learning* menggunakan *Tensorflow* pada departemen *IQC*.

Pada penelitian ini penggunaan mendeteksi kualitas *material* di departemen *IQC*, berikut adalah beberapa hal yang perlu diperhatikan dalam pelatihan model:

1. Kualitas data *train*. Data *train* harus berkualitas baik dan representatif dari semua kategori kualitas yang ingin dideteksi.
2. Ukuran data *train*. Ukuran data *train* yang cukup besar akan membantu model untuk belajar dengan lebih baik.
3. Parameter pelatihan. Parameter pelatihan yang tepat akan membantu model untuk mencapai kinerja yang optimal.

Berikut adalah contoh parameter pelatihan yang dapat disesuaikan:

1. Jumlah layer
2. Ukuran layer
3. Jenis aktivasi
4. Jenis *pooling*

5. Jenis *konvolusi*

Overfitting adalah kondisi di mana model terlalu cocok dengan data *train* dan tidak dapat generalisasi dengan baik ke data baru. Pelatihan Model adalah proses pembelajaran model menggunakan data *train*. Proses ini berlangsung selama beberapa iterasi, di mana model akan diperbarui berdasarkan data pelatihan. Untuk mendeteksi kualitas *material* dengan *deep learning* menggunakan *Tensorflow* pada departemen *IQC*. Monitoring kinerja model dapat membantu Di untuk menentukan apakah pelatihan model sudah cukup atau perlu dilanjutkan. Gunakan teknik regularisasi. Teknik regularisasi dapat membantu untuk mencegah overfitting. Gunakan teknik validasi silang. Teknik validasi silang dapat membantu Di untuk memilih parameter pelatihan yang optimal. Pada kasus penggunaan mendeteksi kualitas *material* di departemen *IQC*, berikut adalah beberapa hal yang perlu diperhatikan dalam pelatihan model: Kualitas data pelatihan. Data pelatihan harus berkualitas baik dan representatif dari semua kategori kualitas yang ingin dideteksi. Ukuran data pelatihan. Ukuran data pelatihan yang cukup besar akan membantu model untuk belajar dengan lebih baik. Parameter pelatihan. Parameter pelatihan yang tepat akan membantu model untuk mencapai kinerja yang optimal. Berikut adalah contoh parameter pelatihan yang dapat disesuaikan: Jumlah layer Ukuran layer Jenis aktivasi Jenis *pooling* Jenis *konvolusi* Di dapat menyesuaikan parameter pelatihan untuk meningkatkan kinerja model. Namun, perlu berhati-hati dalam menyesuaikan parameter pelatihan, karena dapat menyebabkan overfitting. Overfitting adalah kondisi di mana model terlalu cocok dengan data pelatihan dan tidak dapat generalisasi

dengan baik ke data baru. Untuk menghindari overfitting, dapat melakukan teknik-teknik berikut: Gunakan data pelatihan yang cukup gunakan teknik regularisasi gunakan teknik validasi silang.

2.2.7 Validasi Model

Validasi model adalah proses evaluasi kinerja model pada data yang tidak terlihat sebelumnya. Data validasi digunakan untuk mengukur kinerja umum model dan untuk membandingkan kinerja model dengan model lain. Untuk mendeteksi kualitas *material* dengan *deep learning* menggunakan *Tensorflow* pada departemen *IQC*, validasi model dapat dilakukan menggunakan *CNN* untuk mengukur proses kinerja dataset yang tidak digunakan selama pelatihan, yang disebut sebagai set validasi. Teachable machine akan secara otomatis melakukan validasi model menggunakan set uji yang di pilih. di dapat melihat hasil validasi di dashboard teachable machine. Berikut adalah beberapa metrik yang dapat digunakan untuk mengukur kinerja model untuk mendeteksi kualitas *material*.

2.2.8 Optimasi Model

Optimasi model adalah proses meningkatkan kinerja model. Optimasi model dapat dilakukan dengan berbagai cara, seperti mengidentifikasi dan mengatasi overfitting atau underfitting, dan mengoptimalkan hyperparameter. Overfitting adalah kondisi di mana model terlalu cocok dengan data pelatihan dan tidak dapat generalisasi dengan baik ke data baru. Underfitting adalah kondisi di mana model tidak dapat belajar dari data pelatihan dan tidak dapat memberikan hasil yang baik. Pada kasus penggunaan mendeteksi kualitas *material* di departemen *IQC*, overfitting dapat terjadi jika model terlalu kompleks atau jika data pelatihan tidak

representatif. Underfitting dapat terjadi jika model terlalu sederhana atau jika data pelatihan tidak cukup. Pengoptimalan hyperparameter adalah proses mencari nilai hyperparameter yang optimal untuk model. Hyperparameter adalah parameter yang tidak dipelajari oleh model, tetapi ditentukan oleh pengguna.

2.2.9 Implementasi Model

Implementasi model adalah proses menerapkan model ke dalam sistem yang ada. Implementasi model dapat dilakukan dengan berbagai cara, seperti menyesuaikan integrasi dengan sistem yang sudah ada.

2.2.10 Pemeliharaan dan Pemantauan

Pemeliharaan dan pemantauan model adalah proses penting untuk memastikan bahwa model tetap berfungsi dengan baik dan memberikan hasil yang akurat. Pemeliharaan model adalah proses menjaga model tetap up-to-date dan relevan. Pemeliharaan model dapat dilakukan dengan berbagai cara, seperti:

1. Meningkatkan model dengan menggunakan data baru. Data baru dapat digunakan untuk meningkatkan kinerja model.
2. Memperbarui model dengan menggunakan algoritme baru. Algoritme baru dapat meningkatkan kinerja model.
3. Melakukan perbaikan pada model. Perbaikan pada model dapat dilakukan untuk mengatasi masalah yang ditemukan.

Pemantauan kinerja model adalah proses menilai kinerja model secara berkala. Pemantauan kinerja model dapat dilakukan dengan berbagai cara, seperti:

1. Evaluasi model pada set uji. Set uji dapat digunakan untuk menilai kinerja model secara objektif.

2. Analisis hasil deteksi. Hasil deteksi model dapat dianalisis untuk mengidentifikasi masalah yang dapat memengaruhi kinerja model.

Berikut adalah beberapa cara untuk pemeliharaan dan pemantauan model untuk mendeteksi kualitas *material* di departemen *IQC*:

1. Pastikan model memiliki kinerja yang baik sebelum diimplementasikan.
2. Rutin lakukan pemeliharaan model untuk menghindari model yang usang atau tidak relevan.
3. Pantau kinerja model secara berkala dan lakukan penyesuaian jika diperlukan.

2.2.11 Pelatihan Pengguna

Pelatihan pengguna adalah proses mengajar pengguna cara menggunakan sistem. Pelatihan pengguna penting untuk memastikan bahwa pengguna dapat menggunakan sistem dengan aman dan efektif. pelatihan pengguna dapat dilakukan dengan cara berikut:

1. Pelatihan teoritis. Pelatihan teoritis dapat diberikan untuk memperkenalkan pengguna tentang konsep-konsep dasar *deep learning* dan deteksi kualitas *material*.
2. Pelatihan praktik. Pelatihan praktik dapat diberikan untuk memungkinkan pengguna mempelajari cara menggunakan sistem. Pelatihan praktik dapat mencakup: Demonstrasi dari instruktur, Latihan mandiri, Latihan dengan bimbingan.

2.2.12 Evaluasi dan Perbaikan

Evaluasi dan perbaikan adalah proses untuk menilai kinerja model dan melakukan penyesuaian jika diperlukan. Pada penelitian penggunaan mendeteksi kualitas *material* di departemen *IQC*, evaluasi dan perbaikan dapat dilakukan dengan cara berikut :

1. Evaluasi kinerja model secara berkala. Kinerja model dapat dievaluasi dengan menggunakan metrik-metrik seperti akurasi, presisi, recall, dan F1-score.
2. Analisis hasil deteksi untuk mengidentifikasi masalah. Hasil deteksi model dapat dianalisis untuk mengidentifikasi masalah yang dapat memengaruhi kinerja model.
3. Lakukan penyesuaian pada model jika diperlukan. Penyesuaian pada model dapat dilakukan dengan menggunakan teknik-teknik .

Pada kasus penggunaan mendeteksi kualitas *material* di departemen *IQC* dengan menggunakan *teachable machine*, berikut adalah beberapa hal yang perlu diperhatikan dalam evaluasi dan perbaikan: Gunakan data pelatihan yang terbaru. Data pelatihan yang terbaru dapat digunakan untuk meningkatkan kinerja model. Pertimbangkan penggunaan teknik *transfer learning*. Teknik *transfer learning* dapat membantu untuk meningkatkan kinerja model pada dataset yang kecil.

2.3 Hipotesis Penelitian

Deep learning menggunakan *Tensorflow* dapat secara efektif mendeteksi kualitas *material* dengan akurasi yang tinggi dikarenakan menggunakan *CNN*. Alasannya *Deep learning* telah terbukti efektif dalam berbagai tugas pengenalan pola dan klasifikasi, termasuk deteksi kualitas *material*. *Tensorflow* adalah

framework *deep learning* yang populer dan mudah digunakan, sehingga dapat dimanfaatkan untuk mengembangkan model *deep learning* yang akurat untuk deteksi kualitas *material*. Bukti pendukung beberapa penelitian telah menunjukkan bahwa *deep learning* menggunakan *Tensorflow* dapat secara efektif mendeteksi kualitas *material*. Misalnya, sebuah penelitian menggunakan *deep learning* untuk mendeteksi cacat pada permukaan *material* dengan akurasi 98%. Penelitian lain menggunakan *deep learning* untuk memprediksi kerentanan tanah longsor dengan akurasi 95%.

2.4 Penelitian Terdahulu

Telah banyak penelitian yang dilakukan untuk mendeteksi kualitas *material* menggunakan *deep learning*. Beberapa penelitian tersebut antara lain:

1. "Deeplearningforpockmarkdetection"
<https://www.sciencedirect.com/science/article/pii/S0169555X22004172>
 oleh MA Lundine et al. (2023) menggunakan *deep learning* untuk mendeteksi cacat pockmark pada permukaan *material* dengan akurasi 98%
2. "Comparative Study on Distributed Lightweight *Deep learning* for Intelligent Traffic Systems" <https://www.mdpi.com/1424-8220/23/9/4347>] oleh H Tahir et al. (2023) menggunakan *deep learning* untuk mendeteksi objek pada gambar dengan akurasi yang tinggi. Penelitian ini berfokus pada aplikasi *deep learning* untuk sistem transportasi cerdas dan mobil swakemudi.
3. "A New Approach Based on *Tensorflow* Deep *Neural networks* and Geographic Information Systems for Predicting Landslide Susceptibility"

<https://www.mdpi.com/2072-4292/15/14/3458>] oleh TX Truong et al. (2023) menggunakan *deep learning* untuk memprediksi kerentanan tanah longsor dengan akurasi 95%. Penelitian ini menggunakan kombinasi *deep learning* dan sistem informasi geografis (GIS) untuk menganalisis data spasial.

4. Analisis implementasi Quality Control pada produksi gula PT. PERKEBUNAN NUSANTARA (XIV) PERSERO oleh Jumriani

Penelitian-penelitian ini menunjukkan bahwa *deep learning* dapat secara efektif digunakan untuk mendeteksi kualitas *material* dengan akurasi yang tinggi. *Deep learning* dapat menganalisis data gambar dan video untuk mengidentifikasi pola dan cacat yang tidak terlihat oleh mata manusia.