

PENERAPAN KLASIFIKASI CITRA PADA IDENTIFIKASI OBJEK DENGAN PAKAIAN SAFETY MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK* DI PT JAYATAMA SAFETINDO

David Caslan Nababan¹
Sasa Ani Armono²

¹Mahasiswa Program Studi Sistem Informasi, Universitas Putera Batam

²Dosen Program Studi Sistem Informasi, Universitas Putera Batam

email: pb201510039@upbatam.ac.id

ABSTRACT

Construction workers are essential to project execution but face high risks of workplace accidents, often caused by human factors. Advances in artificial intelligence, particularly image processing, provide opportunities to improve the detection of personal protective equipment (PPE), which is currently checked manually and inefficiently. PPE, such as gloves, helmets, and safety shoes, is vital for worker safety but is often neglected due to discomfort. This study uses Convolutional Neural Network (CNN) algorithms to classify images and verify PPE usage at construction sites. CNN processes spatial information through layers for feature extraction, dimension reduction, and classification. A previous study with Faster R-CNN achieved accuracies of 72.83% with TensorFlow and 88.07% with Faster R-CNN. Using a dataset of 200 images, this research, conducted at PT JAYATAMA SAFETINDO, applies Python and TensorFlow to improve PPE detection accuracy. The results aim to support safer workplaces, enhance productivity, and advance AI applications in safety and identification.

Keywords: *Convolutional Neural Network (CNN), Deep Learning, TensorFlow*

PENDAHULUAN

Pekerja konstruksi penting dalam proyek, tetapi faktor manusia sering menyebabkan kecelakaan. Kemajuan kecerdasan buatan meningkatkan akurasi deteksi pakaian keselamatan. Namun, banyak perusahaan masih memeriksa kepatuhan APD secara manual. APD melindungi pekerja dari risiko kerja, tetapi sering tidak digunakan karena alasan ketidaknyamanan, seperti berat perlengkapan atau peningkatan suhu tubuh. (Syafiq and Perdhana 2018)

Deteksi pakaian keselamatan telah menjadi perhatian penting dalam beberapa tahun terakhir karena perannya dalam meningkatkan keselamatan dan produktivitas pekerja konstruksi. Selain itu, sistem ini juga berguna untuk memantau pekerja dan mengidentifikasi aktivitas tidak aman, sehingga dapat mencegah potensi kecelakaan. Dengan pengembangan teknologi deteksi pakaian keselamatan, hal ini menjadi solusi yang menjanjikan untuk mengatasi masalah tersebut, terutama dengan kemajuan

teknologi pengenalan objek secara real-time (Cheng et al. 2022)

Penelitian ini berfokus pada penerapan klasifikasi gambar untuk mendeteksi pakaian keselamatan menggunakan algoritma *Convolutional Neural Network* (CNN). Sistem ini dirancang untuk memastikan pekerja menggunakan pakaian keselamatan lengkap di lokasi konstruksi, dengan gambar sebagai input utama. (Nath, Behzadan, and Paal 2020). Pakaian keselamatan adalah perlengkapan yang melindungi pekerja dari risiko kesehatan dan keselamatan di tempat kerja, digunakan sebagai perlindungan terakhir jika bahaya tidak dapat diatasi secara teknis atau administratif. Jenisnya harus disesuaikan dengan potensi bahaya dan lingkungan kerja. (Sukma Ika Noviarini and Hamengku Prananya 2023)

Penggunaan yang tepat sangat penting untuk mencegah kecelakaan, meskipun kepatuhan pekerja masih rendah, meningkatkan risiko kecelakaan. Contohnya meliputi sarung tangan, sepatu safety, helm, pakaian pelindung, kacamata, dan masker, yang dirancang untuk melindungi tubuh dari berbagai bahaya kerja.

Menurut Jonathan Adiwibowo dalam penelitian yang berjudul "Deteksi Pakaian Safety menggunakan Metode Faster R-CNN," penelitian ini menggunakan metode Faster R-CNN untuk mengembangkan alat pendeteksi pakaian safety. Pendekatan yang diterapkan dalam penelitian ini adalah *Convolutional Neural Network* (CNN).

Penelitian ini memanfaatkan kekuatan CNN untuk mengekstrak fitur dari data gambar menggunakan dataset open image dataset yang sangat beragam. Hasilnya menunjukkan bahwa TensorFlow memiliki tingkat akurasi

sebesar 72.83%, sementara Faster R-CNN memberikan hasil yang cukup memuaskan dengan rata-rata confusion matrix sebesar 93.61% dan akurasi 88.07%. (Adiwibowo, Gunadi, and Setyati 2020)

Penerapan metode klasifikasi citra untuk identifikasi objek yang menggunakan pakaian keselamatan di PT JAYATAMA SAFETINDO dilakukan dengan memanfaatkan *Convolutional Neural Network* (CNN). CNN adalah arsitektur yang terinspirasi oleh konektivitas neuron dalam otak manusia dan dirancang khusus untuk mengolah data dengan hubungan spasial, seperti gambar. Prosesnya melibatkan beberapa lapisan, termasuk lapisan konvolusi yang berfungsi mengekstrak fitur penting dari citra melalui penggunaan channel, serta lapisan pooling yang berperan mengurangi dimensi data sambil mempertahankan fitur yang paling relevan. Data yang telah diproses melalui lapisan-lapisan ini kemudian dikirim ke lapisan fully connected untuk menghasilkan klasifikasi akhir.

Penelitian ini menunjukkan bahwa CNN mampu mencapai tingkat akurasi tinggi dalam mengidentifikasi objek, termasuk objek yang mengenakan pakaian keselamatan, dengan memanfaatkan kemampuannya dalam mempelajari fitur penting dari citra yang diberikan. (Laily, Fajri, and Pratamasunu 2022)

KAJIAN TEORI

2.1 Alat Pelindung Diri (APD)

Alat pelindung diri (APD) adalah perlengkapan yang melindungi pekerja konstruksi dari cedera. APD mencakup helm, sepatu, pakaian pelindung, kacamata, pelindung telinga, sarung tangan, sabuk pengaman, dan respirator. Selain melindungi tubuh, APD

juga mencegah risiko jatuh. APD digunakan jika metode pencegahan lain tidak memungkinkan. Pemilihannya harus sesuai dengan bahaya di lingkungan kerja untuk menjaga keselamatan pekerja (Mentari and Artikel 2020).

2.2 Artificial Intelligence

Kecerdasan Buatan (AI) telah menjadi salah satu topik yang menarik perhatian dalam bidang teknologi. AI merujuk pada kemampuan mesin untuk meniru atau merepresentasikan kecerdasan manusia. Teknologi ini tidak hanya berfokus pada meniru kemampuan fisik manusia, tetapi juga mencakup kemampuan untuk belajar, berpikir logis, dan menyelesaikan masalah seperti yang dilakukan manusia. AI mencakup beragam bidang penelitian, termasuk pembelajaran mesin dan pembelajaran mendalam, serta telah diterapkan di berbagai sektor industri secara global. (Vrontis et al. 2022)

2.2 Deep Learning

Metode pembelajaran mesin yang menggunakan algoritma berbasis jaringan saraf dengan struktur kompleks. Teknik ini belajar lebih mendalam untuk mengenali dan menganalisis data. Dalam sebuah penelitian, deep learning dengan Convolutional Neural Network (CNN) digunakan untuk mendeteksi tumor otak dari citra MRI, dengan akurasi mencapai 99,74%, jauh lebih baik dibandingkan metode sebelumnya. Penggunaan metode ini diharapkan dapat membantu dokter mendiagnosis tumor otak dengan lebih akurat dan mempercepat pengobatan.

2.3 Computer Vision

Visi komputer adalah bidang ilmu komputer yang mengembangkan algoritma dan teknologi untuk memproses dan menganalisis data visual, seperti gambar dan video. Teknologi ini memungkinkan mesin mengenali objek, mengklasifikasikan gambar, melakukan segmentasi, dan melacak pergerakan, mirip dengan cara manusia memproses penglihatan.

Konsep dasar visi komputer adalah mengajarkan komputer untuk memproses dan memahami gambar hingga tingkat piksel. Proses ini meliputi pengambilan, pengolahan, dan interpretasi data visual menggunakan algoritma khusus. Tujuan utamanya adalah membuat sistem yang dapat menganalisis data visual dengan akurasi tinggi, membantu pengambilan keputusan, dan mengotomatiskan tugas-tugas yang biasanya dilakukan secara manual. (Galos and Wang 2024)

2.4 Citra Digital

Citra digital adalah representasi visual dari objek, individu, atau pemandangan yang disimpan dalam bentuk matriks menggunakan elemen berupa sel titik yang terbatas, yang dikenal sebagai piksel. Berdasarkan cara penyimpanan dan struktur datanya, citra digital terbagi menjadi dua jenis utama yaitu, Gambar Raster atau Bitmap dan Gambar Vektor. Perbedaan mendasar antara gambar raster dan vektor terletak pada cara keduanya menyimpan dan merepresentasikan data visual. Gambar raster menggunakan piksel sebagai elemen utama, sedangkan gambar vektor memanfaatkan garis dan kurva berbasis matematika.

2.5 Convolutional Neural Network

Convolutional Neural Network (CNN), atau Jaringan Saraf Konvolusi, adalah metode canggih dalam pengolahan gambar yang menggunakan pembelajaran mendalam untuk menyelesaikan berbagai tugas, baik yang bersifat deskriptif maupun generatif. CNN dirancang dengan struktur yang menyerupai sistem penglihatan manusia, terdiri dari beberapa lapisan yang saling terhubung, sehingga mampu mengurangi kebutuhan pemrosesan data secara manual. Jaringan ini dapat diterapkan melalui kombinasi perangkat keras dan perangkat lunak, dengan prinsip kerja yang meniru fungsi neuron pada otak manusia. (Caggiano et al. 2019)

2.6 Pengukuran Evaluasi

Pengukuran evaluasi adalah proses sistematis untuk mengumpulkan dan menganalisis informasi guna menilai suatu objek atau fenomena. Proses ini terdiri dari:

1. Pengukuran: Membandingkan hasil dengan kriteria yang ditetapkan.
2. Penilaian: Menginterpretasikan dan menjelaskan hasil pengukuran.

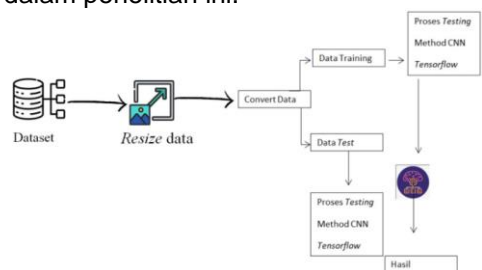
Dalam penelitian ini, metode evaluasi yang digunakan meliputi, recall, accuracy, dan precision:

1. Recall: Mengukur persentase data positif yang berhasil dikenali model.
2. Accuracy: Menilai seberapa sering model membuat prediksi yang benar.
3. Precision: Mengukur keakuratan prediksi positif model.

Hasil evaluasi divisualisasikan dengan matriks kebingungan, yang menunjukkan hubungan antara prediksi model dan kondisi sebenarnya.

METODE PENELITIAN

Penelitian ini menggunakan metode eksperimen untuk menilai efektivitas deep learning dengan TensorFlow dalam mendeteksi pakaian keselamatan. Metode ini dipilih karena memungkinkan pengujian yang terukur dan memberikan pemahaman lebih dalam tentang teknologi ini. Pendekatan kuantitatif dipilih karena penelitian ini menganalisis data numerik untuk mengukur akurasi deteksi pakaian keselamatan. Metode ini mendukung pengumpulan data sistematis dan analisis statistik mendalam, sehingga memungkinkan penilaian objektif terhadap model deep learning. Oleh karena itu, pendekatan ini paling sesuai untuk mengevaluasi kinerja TensorFlow dalam penelitian ini.



Gambar 3.1 Tahapan penelitian

1. Dataset
Dataset adalah kumpulan gambar yang digunakan untuk mengklasifikasikan penggunaan pakaian keselamatan.
2. Resize Data
Tahap ini menyesuaikan ukuran gambar agar sesuai dengan input model CNN, menjaga konsistensi data untuk pelatihan dan pengujian.
3. Convert Data
Setelah di-resize, gambar dikonversi ke format numerik agar dapat diolah oleh TensorFlow. Nilai

piksel dinormalisasi ke rentang 0-1 untuk mempercepat pelatihan model.

4. Data Training

Dataset dibagi menjadi data pelatihan dan pengujian. Data pelatihan melatih model CNN untuk mengenali pola pakaian keselamatan dengan mengoptimalkan bobot model.

5. Data Test

Data pengujian digunakan untuk menilai kinerja model yang telah dilatih. Data ini tidak digunakan selama proses pelatihan untuk memastikan evaluasi dilakukan secara objektif. Model diuji untuk menentukan sejauh mana kemampuannya mengklasifikasikan gambar yang belum pernah dilihat sebelumnya.

6. Proses Training

Pada tahap ini, model CNN yang telah dilatih digunakan untuk mengklasifikasikan gambar baru. Proses pengujian dilakukan menggunakan TensorFlow, yang menyediakan berbagai fitur untuk implementasi CNN. Model akan menghasilkan output berupa prediksi, apakah gambar termasuk dalam kategori "Menggunakan Pakaian Safety" atau "Tidak Menggunakan Pakaian Safety."

7. Hasil

Hasil akhir penelitian berupa label prediksi dari model, seperti "Menggunakan Pakaian Safety" atau "Tidak Menggunakan Pakaian Safety." Hasil ini digunakan untuk mengevaluasi akurasi model serta untuk aplikasi praktis, seperti pemantauan pekerja di PT Jayatama Safetindo.

HASIL DAN PEMBAHASAN

Setelah tahap pemodelan Convolutional Neural Network (CNN) selesai, kinerja model dievaluasi dengan menghitung tingkat akurasi. Proses pelatihan dilakukan selama 20 iterasi dengan laju pembelajaran sebesar 0,001. Nilai-nilai hiperparameter ini ditentukan secara empiris untuk mengoptimalkan kinerja model. Hasil evaluasi yang diperoleh menggunakan Framework TensorFlow menunjukkan tingkat akurasi model.

	precision	recall	f1-score	support
	precision	recall	f1-score	support
0	0.9961	0.9847	0.9904	262
1	0.9912	0.9978	0.9945	453
macro avg	0.9937	0.9913	0.9925	715
weighted avg	0.9930	0.9930	0.9930	715

Gambar 4.1 Hasil evaluasi yang diperoleh menggunakan *Framework TensorFlow1*.

1. Persiapan

Tahapan pertama adalah menginstal Anaconda dan TensorFlow. Berikut langkah-langkah instalasi Anaconda:

1. Unduh Anaconda: Kunjungi situs resmi Anaconda (<https://www.anaconda.com/download>) dan pilih versi sesuai sistem operasi.
2. Instalasi: Jalankan file yang diunduh, lalu ikuti instruksi pada installer.
3. Verifikasi: Buka Anaconda Navigator atau terminal, lalu jalankan `conda --version` untuk memastikan instalasi berhasil.

Langkah instalasi TensorFlow setelah menginstal Anaconda:

1. Buat Lingkungan Virtual: Buka terminal atau Anaconda Prompt, lalu buat lingkungan dengan perintah `conda create -n tf_env python=3.8`.

2. Aktifkan Lingkungan: Aktifkan lingkungan virtual dengan perintah ``conda activate tf_env``.
3. Instal TensorFlow: Instal TensorFlow dengan perintah ``conda install tensorflow``.
4. Verifikasi Instalasi: Pastikan TensorFlow terinstal dengan menjalankan skrip atau kode yang menggunakan TensorFlow.

2. Preprocessing Image

Setelah mendapatkan dataset gambar berpakaian safety, langkah selanjutnya adalah preprocessing image. Berikut langkah-langkah preprocessing yang akan diterapkan.:

1. Pelabelan Gambar
Pelabelan gambar dilakukan dengan format XML Pascal VOC. Ini adalah langkah awal membangun dataset, di mana 400 gambar berpakaian safety dilabeli secara manual menggunakan alat Label Img.



Gambar 4.2 Labeling Gambar

2. Konversi Dataset
Konversi data mengubah format yang dilabeli agar cocok dengan TensorFlow, mulai dari XML ke CSV, lalu CSV ke TFRecord. Setelah pelabelan selesai, dataset diubah dari XML ke CSV menggunakan Python. Algoritma konversi XML ke CSV dijelaskan dalam pseudocode. Berikut tahapan-tahapannya:

- a) Mengimport file XML.
- b) Mengimport pustaka csv.
- c) Mendefinisikan array yang akan digunakan.
- d) Membuat direktori untuk data latih dan uji.

Setelah menyimpan kode, file dikonversi dengan menjalankan perintah berikut.

```
Python xml_tocsv.py
```

Eksekusi instruksi tersebut akan menghasilkan file CSV yang tersimpan di pustaka TensorFlow.

3. Konversi Dataset CSV KE TFRecord

Setelah berhasil mengonversi dataset dari XML ke CSV, tahap selanjutnya adalah mengonversi data CSV tersebut ke format TFRecord. Konversi ke TFRecord ini bertujuan untuk mempermudah pertukaran data selama proses pelatihan. Algoritma untuk konversi dari format CSV ke TFRecord dijelaskan dalam pseudocode. Berikut tahapan-tahapannya:

1. Mengimport pustaka TensorFlow.
2. Mengimport jalur file gambar.
3. Membuat kelas untuk klasifikasi data.
4. Mengidentifikasi format file gambar (jpg/png).
5. Mendeklarasikan variabel Xmins, Xmaxs, Ymins, dan Ymaxs.

Setelah menyimpan kode di atas, konversi file dilakukan dengan menjalankan perintah berikut:

```
# Untuk data latihan python
generate_tfrecored.py -- type=train --
csv_input=data/train_labels.csv --
output_path=data/train.record # dan
untuk data uji python
generate_tfrecored.py -- type=test --
csv_input=data/test_labels.csv--
```

Eksekusi perintah tersebut akan secara otomatis mengintegrasikan file tfrecored ke dalam pustaka TensorFlow.

4. Pengolahan Image Dengan TensorFlow

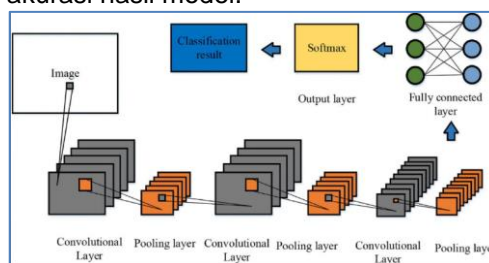
Komponen konfigurasi dalam pipeline deteksi objek ini terdiri dari kumpulan berkas atau direktori yang dimasukkan ke dalam TensorFlow. Berikut struktur file yang diinput ke TensorFlow menggunakan Python:

1. Anotasi adalah proses Anotasi adalah proses menambahkan label atau metadata pada data (seperti gambar, teks, atau suara) untuk membantu mesin memahami pola dalam data.
2. Direktori data berisi berkas dengan ekstensi .record dan .csv.
3. Images terdiri dari dua subdirektori, yaitu subdirektori uji (test) dan subdirektori latihan (train), yang masing-masing berisi berkas gambar.
4. Direktori pelatihan berisi berkas konfigurasi pipeline yang digunakan dalam proses pelatihan deteksi objek.

5. Membangun Model CNN

Setelah menyelesaikan serangkaian tahapan, termasuk proses pelabelan, konversi data, dan penyiapan folder untuk pipeline deteksi objek, proses

selanjutnya adalah melatih data yang telah dikumpulkan menggunakan algoritma *Convolutional Neural Network* (CNN). Struktur model jaringan algoritma CNN memiliki pengaruh besar terhadap akurasi hasil model.



Gambar 4.3 Model jaringan

Visualisasi di atas menunjukkan proses pemodelan jaringan pada tahap pelatihan untuk menghasilkan model yang simpel dan akurat. Penelitian ini menggunakan gambar berukuran 300x300 piksel sebagai input. Data yang telah dikumpulkan dilatih dengan algoritma CNN setelah melalui pelabelan, konversi data, dan penyiapan folder dalam pipeline deteksi objek. Struktur model jaringan CNN memiliki pengaruh besar terhadap akurasi hasil yang diperoleh

1. Pada tahap awal konvolusi, digunakan kernel 3x3 dengan 80 filter. Dua matriks digabungkan untuk menghasilkan matriks baru. Setelah konvolusi, ditambahkan fungsi aktivasi RELU yang mengubah nilai negatif menjadi nol. Padding 0 digunakan agar ukuran hasil konvolusi tetap 300x300.
2. Langkah *pooling* bertujuan untuk mengurangi dimensi matriks menggunakan operasi *pooling*. Lapisan *pooling* berisi filter yang ukuran nilai matriksnya berpindah secara bergantian pada area feature maps. Hasil dari tahap



- pooling adalah matriks nilai baru. Penelitian ini menggunakan aktivasi *maxpooling*, di mana nilai maksimum diambil berdasarkan pergeseran *kernel* nya.
3. Pada tahap konvolusi kedua, output dari tahap *pooling* pertama diolah. Matriks gambar berukuran 40x40 digunakan sebagai input, dengan 150 filter dan *kernel* berukuran 3x3. Fungsi aktivasi *RELU* diterapkan pada tahap ini.
 4. Selanjutnya, dilakukan *pooling* kedua yang mengikuti proses serupa dengan *pooling* pertama. Perbedaannya hanya terletak pada dimensi akhir matriks output, di mana *pooling* kedua menghasilkan output berukuran 75x75.
 5. Selanjutnya, tahap *flatten* atau fully connected dimulai. Tahap ini hanya memiliki satu hidden layer. Pada tahap *flatten*, output dari layer *pooling* diubah menjadi vektor. Proses deteksi gambar kemudian dilakukan pada tahap ini
 6. Pada langkah terakhir, fungsi aktivasi softmax diterapkan. Fungsi ini umumnya digunakan dalam deteksi analisis diskriminan linear multikelas dan regresi logistik multinomial.
- Penerapan model jaringan CNN pada teks sebelumnya berfokus pada tahap pelatihan. Struktur model CNN

yang diperoleh dari proses pelatihan tersebut dapat dilihat di bawah ini.

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 226, 226, 32)	896
max_pooling2d (MaxPooling2D)	(None, 113, 113, 32)	0
conv2d_1 (Conv2D)	(None, 111, 111, 32)	9,248
max_pooling2d_1 (MaxPooling2D)	(None, 55, 55, 32)	0
conv2d_2 (Conv2D)	(None, 53, 53, 64)	18,496
max_pooling2d_2 (MaxPooling2D)	(None, 26, 26, 64)	0
conv2d_3 (Conv2D)	(None, 24, 24, 64)	36,928
max_pooling2d_3 (MaxPooling2D)	(None, 12, 12, 64)	0
conv2d_4 (Conv2D)	(None, 18, 18, 64)	36,928
max_pooling2d_4 (MaxPooling2D)	(None, 5, 5, 64)	0
flatten (Flatten)	(None, 1680)	0
dense (Dense)	(None, 1824)	1,639,424
dropout (Dropout)	(None, 1824)	0
dense_1 (Dense)	(None, 128)	131,200
dropout_1 (Dropout)	(None, 128)	0
dense_2 (Dense)	(None, 2)	258

Total params: 5,620,136 (21.44 MB)
 Trainable params: 1,873,378 (7.15 MB)
 Non-trainable params: 0 (0.00 B)
 optimizer params: 3,746,758 (14.29 MB)

Gambar 4. 4 Hasil Convolutional

Tabel di atas menunjukkan hasil pelatihan model jaringan CNN, seperti yang dapat dilihat pada ilustrasi sebelumnya. Rumus "input_size + 2*padding - (filter_size - 1)" digunakan untuk menghitung input pada lapisan konvolusional. Hasil pemodelan ini menghasilkan total parameter sebanyak 2976385 neuron.

6. Penghitungan Konvolusi

Untuk mempermudah pemahaman, peneliti mengambil sampel dari bagian tertentu matriks gambar masukan berukuran 80x80 piksel. Hanya sebagian matriks yang digunakan dalam proses konvolusi.

164	163	161	161	161	163										
152	152	153	153	153	154										
135	137	139	138	136	136	*	1	0	-1	=	-2	-3	-11	-4	
114	117	120	119	116	114		1	0	-1		0	37	-4	7	
88	92	96	98	99	100		1	0	-1		3	47	7	6	
63	66	72	30	88	96										

Gambar 4.5 Matriks

Gambar 4.5 menunjukkan penggunaan kernel 3x3 dengan stride 1. Artinya, kernel

akan bergerak satu piksel ke kanan atau bawah pada setiap langkah konvolusi.

Dengan padding 1, kami menambahkan bingkai nol di sekitar gambar input untuk menjaga dimensi output.

7. Proses Pooling

Max pooling, sebagai salah satu metode pooling yang paling umum, bekerja dengan cara memilih nilai terbesar dari suatu wilayah pada matriks. Proses ini dapat dijelaskan sebagai berikut:

-2	-3	-11	-4		37	7
0	37	-4	7	=	47	7
3	47	7	6			

Gambar 4.6 Hasil Pooling

Ilustrasi di atas menunjukkan bahwa proses pooling yang diterapkan menggunakan filter berukuran 2x2 dengan pergeseran (stride) sebesar 1 piksel. Metode pooling yang digunakan adalah max pooling, di mana nilai piksel tertinggi dalam setiap wilayah filter 2x2 akan dipilih. Dengan demikian, hasil pooling akan menghasilkan matriks berukuran 2x2 yang berisi nilai-nilai maksimum dari fitur-fitur yang telah diekstrak oleh lapisan konvolusi sebelumnya.

8. Proses Fully Connected

Output dari tahap sebelumnya masih berbentuk matriks multidimensi. Agar dapat diproses oleh lapisan yang sepenuhnya terhubung, kita perlu mengubah bentuk matriks ini menjadi vektor. Fungsi flatten digunakan untuk mengubah bentuk data menjadi vektor satu dimensi. Tujuannya adalah agar data siap untuk diproses oleh lapisan dense. Lapisan dense kemudian ditambahkan untuk melakukan klasifikasi, yaitu untuk menentukan kelas dari suatu data.

9. Proses Classification

Proses klasifikasi bertujuan mengenali wilayah spesifik pada setiap piksel gambar untuk merekonstruksi pola

pakaian keselamatan. Penelitian ini menguji sistem dengan berbagai citra, termasuk pekerja dengan pakaian keselamatan lengkap atau tidak, serta dari sudut pandang berbeda. Tujuannya adalah menilai akurasi sistem dalam mengklasifikasikan pakaian keselamatan meskipun ada perbedaan kualitas dan sudut gambar.

10. Hasil Model training

Setelah pemodelan CNN selesai, kinerja model dievaluasi dengan menghitung akurasi. Pelatihan dilakukan dalam 20 iterasi dengan laju belajar 0,001. Hiperparameter dipilih secara empiris untuk meningkatkan kinerja. Evaluasi dengan TensorFlow mencatat tingkat akurasi model.

precision	recall	f1-score	support	
	precision	recall	f1-score	support
0	0.9961	0.9847	0.9904	262
1	0.9912	0.9978	0.9945	453
macro avg	0.9937	0.9913	0.9925	715
weighted avg	0.9930	0.9930	0.9930	715

Gambar 4.7 Hasil Model training

11. Penentuan Parameter Model

Penelitian ini bertujuan menemukan konfigurasi terbaik untuk model Convolutional Neural Network (CNN). Eksperimen dilakukan dengan mengubah beberapa parameter, seperti jumlah epoch, ukuran data latih, dan laju pembelajaran. Tujuannya adalah mendapatkan kombinasi parameter yang menghasilkan kinerja model terbaik.

Pengaruh Jumlah Epoch

Epoch adalah satu siklus pelatihan di mana seluruh data latih diproses. Untuk dataset besar, pelatihan satu epoch bisa memakan waktu lama, sehingga data biasanya dibagi menjadi batch kecil. Ukuran batch memengaruhi kinerja model secara signifikan. Penelitian ini

mengevaluasi pengaruh jumlah epoch terhadap kinerja model menggunakan TensorFlow sebagai framework.

```
Epoch 1/35
C:\Users\12345dc\anaconda3\Lib\site-packages\keras\src\backend\tensorflow\inn.py:609: UserWarning: "'sparse_categorical_crossentropy' received 'from_logits=True', but the 'output' argument was produced by a Softmax activation and thus does not represent logits. Was this intended?
output, from_logits = _get_logits(
4/4 ----- 71s 16s/step - accuracy: 0.5107 - loss: 27.8879 - val_accuracy: 0.9479 - val_loss: 0.6871
Epoch 2/35
4/4 ----- 68s 12s/step - accuracy: 0.7220 - loss: 3.3739 - val_accuracy: 0.9479 - val_loss: 1.6882
Epoch 3/35
4/4 ----- 82s 12s/step - accuracy: 0.9059 - loss: 2.6028 - val_accuracy: 0.9479 - val_loss: 0.5058
Epoch 4/35
4/4 ----- 43s 12s/step - accuracy: 0.9108 - loss: 0.4715 - val_accuracy: 0.9479 - val_loss: 0.1847
Epoch 5/35
4/4 ----- 86s 12s/step - accuracy: 0.9102 - loss: 0.3296 - val_accuracy: 0.9479 - val_loss: 0.1855
```

Gambar 4.8 Pengaruh Jumlah Epoch

Pengaruh Ukuran Data Pelatihan

Untuk menganalisis pengaruh ukuran dataset terhadap kinerja model, data pelatihan dibagi menjadi tiga kelompok dengan jumlah masing-masing 200, 400, dan 800 sampel. Setiap kelompok

digunakan secara terpisah untuk melatih model. Hasil eksperimen ini bertujuan untuk mengamati bagaimana variasi ukuran dataset memengaruhi akurasi dan kinerja model secara keseluruhan.

Tabel 4.1 Pengaruh Ukuran Data Pelatihan


Data training	val_accuracy	val_loss	Time (s)
200	0.9479	0.5058	82s
400	0.9479	0.1847	43s
800	0.9479	1,6882	68s

Berdasarkan hasil eksperimen menunjukkan bahwa model CNN yang dilatih dengan 200, 400, dan 800 sampel mencapai akurasi 88–96% dalam mendeteksi pelanggaran penggunaan alat pelindung diri. Ini menunjukkan bahwa peningkatan jumlah data pelatihan meningkatkan akurasi model dalam mengklasifikasikan gambar.

Pengaruh Jumlah Nilai Learning Rate

Tingkat pembelajaran (learning rate) adalah pengaturan penting dalam algoritma penurunan gradien untuk mencari nilai minimum lokal. Pada penelitian ini, diterapkan tiga tingkat pembelajaran: 0.1, 0.6, dan 1. Hasil

penelitian menunjukkan bahwa pemilihan tingkat pembelajaran memengaruhi keakuratan model. Grafik berikut menunjukkan perbandingan kinerja model untuk setiap tingkat pembelajaran.



Gambar 4.9 Tingkat Pembelajaran Learning Test

Pengujian dengan deep learning menggunakan TensorFlow menunjukkan keberhasilan model dalam mendeteksi dan mengklasifikasikan pakaian yang sesuai dengan standar keselamatan. Teknologi deep learning memungkinkan model untuk secara otomatis menganalisis data dari dataset pelatihan dan mengenali karakteristik yang menentukan apakah suatu jenis pakaian tergolong aman atau tidak.



Gambar 4.10 Hasil Pengujian

Keberhasilan implementasi deep learning dalam TensorFlow terlihat dari hasil deteksi yang dihasilkan. Pemeriksaan hasil deteksi ini memberikan pemahaman lebih mendalam, yang sangat penting untuk memverifikasi kinerja model. Hal ini memastikan bahwa pakaian yang dikategorikan sebagai aman oleh model benar-benar memenuhi standar keselamatan yang diharapkan.

SIMPULAN

Studi kami menunjukkan bahwa deep learning menggunakan TensorFlow dan Convolutional Neural Network (CNN) dapat meningkatkan akurasi pengidentifikasian objek dengan alat

pengaman di tempat kerja. Hasilnya menunjukkan bahwa teknik yang diusulkan dapat secara efektif mengklasifikasikan peralatan keselamatan, yang sangat penting untuk menjamin keselamatan dan produktivitas pekerja. Penelitian kami menunjukkan bahwa teknologi ini dapat ditingkatkan dalam sistem keselamatan yang sudah ada. Penelitian di masa depan harus menyelidiki kemungkinan teknik ini dalam berbagai konteks industri serta mengevaluasi skalabilitasnya. Pada akhirnya, penelitian kami menekankan betapa pentingnya menggunakan AI untuk meningkatkan keselamatan di tempat kerja dan mencegah kecelakaan.

DAFTAR PUSTAKA

- Adiwibowo, Jonathan, Kartika Gunadi, and Endang Setyati. 2020. "Deteksi Alat Pelindung Diri Menggunakan Metode YOLO Dan Faster R-CNN." *Jurnal Infra* 8(2):106–12.
- Caggiano, Alessandra, Jianjing Zhang, Vittorio Alfieri, Fabrizia Caiazzo, Robert Gao, and Roberto Teti. 2019. "Machine Learning-Based Image Processing for on-Line Defect Recognition in Additive Manufacturing." *CIRP Annals* 68(1):451–54. doi: 10.1016/j.cirp.2019.03.021.
- Cheng, Jack C. P., Peter Kok Yiu Wong, Han Luo, Mingzhu Wang, and Pak Him Leung. 2022. "Vision-Based Monitoring of Site Safety Compliance Based on Worker Re-Identification and Personal Protective Equipment Classification." *Automation in Construction* 139. doi: 10.1016/j.autcon.2022.104312.
- Galos, Joel, and Xiaoying Wang. 2024. "Demonstration of Computer Vision

- for Void Characterisation of 3D-Printed Continuous Carbon Fibre Composites.” *Results in Materials* 22(February):100566. doi: 10.1016/j.rinma.2024.100566.
- Laily, Milzamah Elvi, Fathorazi Nur Fajri, and Gulpi Qorik Oktagalu Pratamasunu. 2022. “Deteksi Penggunaan Alat Pelindung Diri (APD) Untuk Keselamatan Dan Kesehatan Kerja Menggunakan Metode Mask Region Convolutional Neural Network (Mask R-CNN).” *Jurnal Komputer Terapan* 8(2):279–88. doi: 10.35143/jkt.v8i2.5732.
- Mentari, Trinita Septi, and Info Artikel. 2020. “Kepatuhan Pemakaian Alat Pelindung Diri Pada Pekerja Proyek.” *Higeia Journal of Public Health Research and Development* 4(4):610–20.
- Nath, Nipun D., Amir H. Behzadan, and Stephanie G. Paal. 2020. “Deep Learning for Site Safety: Real-Time Detection of Personal Protective Equipment.” *Automation in Construction* 112(July 2019):103085. doi: 10.1016/j.autcon.2020.103085.
- Sukma Ika Noviarmi, Fadilatus, and Lanobyan Hamengku Prananya. 2023. “Hubungan Masa Kerja, Pengawasan, Kenyamanan APD Dengan Perilaku Kepatuhan Penggunaan Alat Pelindung Diri (APD) Pada Pekerja Area PA Plant PT X.” *Jurnal Keselamatan Kesehatan Kerja Dan Lingkungan* 4(1):57–66. doi: 10.25077/jk3l.4.1.57-66.2023.
- Syafiq, Umar, and Surya Perdhana. 2018. “Kecelakaan Kerja Pada Perusahaan Konstruksi: Sebuah Telaah Literatur.” *Diponegoro Journal Of Management* 7(1981):1–9.
- Vrontis, Demetris, Michael Christofi, Vijay Pereira, Shlomo Tarba, Anna Makrides, and Eleni Trichina. 2022. “Artificial Intelligence, Robotics, Advanced Technologies and Human Resource Management: A Systematic Review.” *International Journal of Human Resource Management* 33(6):1237–66. doi: 10.1080/09585192.2020.1871398.

	Penulis pertama, David Caslan Nababan, merupakan mahasiswa Prodi Sistem Informasi Universitas Putera Batam.....
	Penulis kedua, Sasa Ani Armono, merupakan Dosen Prodi Sistem Informasi Universitas Putera Batam.