

Eksplorasi Keandalan Sistem Sortir dan Klasifikasi Kecacatan Perekat Kemasan Menggunakan Arsitektur *UNet-Inception* *Convolutional Neural Network*

Richo¹, Ryan Yudha Adhitya², Muhammad Khoirul Hasin³, Mat Syai'in⁴, Edy Setiawan⁵
e-mail: ¹richo@student.ppns.ac.id, ²ryanyudhaadhitya@ppns.ac.id, ³khoirul.hasin@ppns.ac.id,
⁴matt.syaiin@ppns.ac.id, ⁵edy_setiawan@ppns.ac.id

^{1,2,3,4,5} Jurusan Teknik Kelistrikan Kapal, Program Studi Teknik Otomasi, Politeknik Perkapalan Negeri Surabaya, Jalan Teknik Kimia
Kampus ITS, Surabaya, Indonesia

Informasi Artikel

Riwayat Artikel

Diterima 12 Agustus 2023
Direvisi 5 September 2023
Diterbitkan 30 September 2023

Kata kunci:

UNet-Inception
CNN
Sortir
Kecacatan
Klasifikasi

Keywords:

UNet-Inception
CNN
Sort
Defects
Classification

ABSTRAK

Kualitas standarisasi kelayakan kemasan menjadi parameter utama pada bidang industri untuk mencapai visi dan misi perusahaan dalam memastikan produk yang dihasilkan telah memenuhi standar yang diharapkan. Sistem pemilahan produk umumnya masih dilakukan dengan cara manual dengan pengamatan visual yang rentan terhadap ketidakakuratan dan interpretasi subjektif oleh operator yang menyebabkan kesalahan dalam mengenali kategori produk. Penelitian ini melakukan perancangan sistem sortir produk dengan penambahan arsitektur *UNet-Inception* pada model CNN. Arsitektur *UNet-Inception* yang dikembangkan peneliti memiliki konstruksi *layer* konvolusi sebanyak 5 *layer*, *pooling layer* sebanyak 2 *layer*, *up sampling* 1 *layer*, serta pola *concatenate* sebanyak 1 *layer*, penambahan *layer inception convolutional* (*Concv2D*) dengan *neuron hidden* sebanyak 128 *neuron*. Model dengan penambahan arsitektur *UNet-Inception* berhasil mencapai tingkat akurasi *training* yang lebih tinggi daripada model tanpa arsitektur *UNet-Inception* dengan perbandingan yakni 98,39% berbanding 71,47%. Pada pengujian deteksi *real-time* didapatkan akurasi sebesar 93,34%. Sistem yang diciptakan mampu melakukan klasifikasi produk dengan sangat baik berdasarkan karakteristik bercak pada panjang bercak 3 cm, 5 cm, dan 7 cm, dengan akurasi keberhasilan mencapai 100%. Sistem integrasi dalam bentuk sortir yang telah diimplementasikan berhasil memberikan respons aksi *reject* yang sesuai hasil deteksi produk cacat dengan akurasi keberhasilan mencapai 100%.

ABSTRACT

The standardized quality of packaging feasibility is the main parameter in the industrial sector to achieve the company's vision and mission in ensuring the products produced meet the expected standards. Product sorting systems are generally still carried out manually with visual observations which are prone to inaccuracies and subjective interpretations by operators which lead to errors in product identification. This study designed a product sorting system with the addition of the UNet-Inception architecture to the CNN model. The UNet-Inception architecture developed by researchers has a construction of 5 layers of convolutional layers, 2 layers of pooling layers, 1 layer of up sampling, and 1 layer of concatenate patterns, the addition of a convolutional inception layer (Concv2D) with hidden neurons of 128 neurons. The model with the addition of the UNet-Inception architecture managed to achieve a higher level of training accuracy than the model without the UNet-Inception architecture with a ratio of 98.39% to 71.47%. In



the real-time detection test, an accuracy of 93.34% was obtained. The system created was able to classify products very well based on the characteristics of the spots at the spot lengths of 3 cm, 5 cm and 7 cm, with an accuracy of success reaching 100%. The integrated system in the form of sort that has been implemented has succeeded in providing a reject action response that is in accordance with the results of defective product detection with a success accuracy of up to 100%.

Penulis Korespondensi:

Richo,
Jurusan Teknik Kelistrikan Kapal, Program Studi Teknik Otomasi,
Politeknik Perkapalan Negeri Surabaya,
Kampus ITS Sukolilo, Jl. Teknik Kimia, Keputih, Sukolilo, Surabaya, Jawa Timur, Indonesia, Kode Pos 60111.
Email: richo@student.ppns.ac.id
Nomor HP/WA aktif: +62 823-3973-9702

1. PENDAHULUAN

Dalam menjamin kualitas standarisasi kelayakan kemasan dan pemilihan produk yang berkualitas umumnya menjadi parameter utama pada bidang industri [1]. Hal ini menjadi *point* primadona untuk mencapai visi dan misi perusahaan dalam memastikan produk yang dihasilkan telah memenuhi standar yang diharapkan. Untuk mencapai harapan tersebut, sudah seharusnya dibutuhkan teknologi berbasis *image processing* dan *automation system* sehingga tujuan dalam memilah produk yang berkualitas dapat diimplementasikan dengan optimal [2]. Namun pada permasalahan yang ada, sistem pemilahan produk cacat pada bidang industri khususnya pada industri produksi tepung terigu masih dilakukan dengan cara manual, dimana operator menjadi subjek utama dalam memilah produk melalui pengamatan visual secara langsung. Proses pemilahan secara manual rentan terhadap ketidakakuratan dan interpretasi subjektif oleh operator yang menyebabkan kesalahan dalam mengenali produk cacat atau produk normal [3]. Selain itu kesalahan dalam pengamatan oleh operator juga dapat berdampak pada citra merek produk, kepuasan pelanggan, mempengaruhi penjualan, serta terancamnya reputasi perusahaan [4].

Berdasarkan analisis permasalahan yang telah dilakukan oleh peneliti, indikasi utama bagi operator dalam mengenali produk cacat adalah dengan mengamati kerusakan pada area perekat atau adhesif kemasan tepung terigu. Kerusakan tersebut mengakibatkan adhesif kemasan tidak menempel dengan baik, sehingga memicu terhamburnya tepung pada area adhesif kemasan ketika proses *transfer* produk pada area *packing*. Adanya hal tersebut, penulis menetapkan parameter kerusakan berdasarkan bercak tepung yang tersebar pada area adhesif kemasan yang dapat dikenali oleh *web camera* sebagai indikasi cacat produk menggunakan metode CNN.

Penelitian sejenis sebelumnya telah dilakukan dengan judul "Analisis Pengaruh Optimizer pada Model CNN untuk Identifikasi Cacat pada Perekat Kemasan" [5]. Temuan dari penelitian tersebut mengungkapkan bahwa optimizer berpengaruh dalam meningkatkan akurasi pengenalan produk dan meminimalisir terjadinya *overfitting*. Selain itu, dalam penelitian tersebut, metode *Convolutional Neural Network* (CNN) yang telah terbukti mampu mengenali produk kemasan dengan akurasi yang signifikan hanya pada *input* gambar yang telah diidentifikasi yakni data *training* dan data *testing*. Namun, meskipun pencapaian ini telah dihasilkan, masih terdapat tantangan dalam mengintegrasikan sistem deteksi dengan mikrokontroler dan implementasi pengenalan produk yang belum diidentifikasi secara *real time*, serta membangun arsitektur yang kompleks pada model CNN sehingga pengenalan dan klasifikasi produk dapat lebih optimal. Oleh karena itu, sebagai langkah pengembangan lebih lanjut, peneliti melakukan penelitian dengan pengembangan yang berfokus pada integrasi sistem secara komprehensif dengan melibatkan penyusunan sistem sortir yang berperan sebagai tindakan *reject* terhadap produk cacat yang terdeteksi, sehingga hal tersebut dapat meningkatkan kualitas produksi yang sesuai *standard* dalam memilah produk cacat. Penelitian ini juga memperkenalkan dan menganalisis keandalan arsitektur *UNet-Inception* pada model CNN untuk menghasilkan keakuratan klasifikasi cacat produk secara *real-time*. Hal ini dilakukan sebagai langkah penyempurnaan untuk mengenali produk yang sebelumnya belum pernah dikenali oleh sistem dalam menghadapi tantangan terhadap pengenalan pola *sample* produksi yang beragam.



Penelitian terkait keandalan arsitektur *UNet-Inception* CNN dalam meningkatkan akurasi telah dilakukan dalam beberapa kesempatan, salah satu contohnya yakni penggunaan arsitektur *UNet-Inception*. Dalam penelitian yang dilakukan oleh Redina [6] dengan fokus utamanya yakni merancang arsitektur *UNet-Inception* pada model CNN untuk klasifikasi citra tumor otak. Hasil dari penelitian tersebut menunjukkan bahwa penambahan arsitektur *UNet-Inception* telah menghasilkan akurasi model yang sangat baik dengan akurasi mencapai 96,29%. *UNet-Inception* merupakan hasil penggabungan antara arsitektur *UNet* dan *Inception*, penelitian tersebut menggabungkan kedua arsitektur karena pada arsitektur *UNet* memiliki struktur *skip connections* yang menghubungkan lapisan *encoding* dengan *decoding* [7], sementara itu arsitektur *inception* menggabungkan informasi dari berbagai ukuran *kernel* sehingga memungkinkan model untuk mendeteksi fitur dari skala terkecil pada gambar [8]. Gabungan dari kedua arsitektur tersebut menjadi faktor utama dalam terciptanya penelitian ini sebagai identifikasi detail-detail halus seperti bercak tepung dengan skala terkecil.

Penelitian ini dirancang dengan total *dataset* sebanyak 300 data, dimana 270 data merupakan data *training*, sedangkan 30 data lainnya merupakan data *testing* yang terdiri dari data dengan kategori cacat dan normal. Setiap data memiliki ukuran dimensional sebesar 200x200 *pixel*. Pada implementasi *layer* arsitektur *UNet-Inception*, peneliti menyusun model dengan *layer* konvolusi sebanyak 5 *layer*, *pooling layer* sebanyak 2 *layer*, *up sampling* 1 *layer*, serta pola *concatenate* sebanyak 1 *layer*, penambahan *layer inception convolutional* (Conv2D) dengan *neuron hidden* sebanyak 128 *neuron*, optimasi sistem menggunakan optimizer Adam, seta *UpSampling* 2 dimensional dengan ukuran matriks sebesar 2x2.

Dengan adanya penelitian ini, diharapkan dapat terciptanya akurasi model yang unggul dengan modifikasi arsitektur *UNet-Inception* CNN dalam mengenali detail-detail halus seperti bercak tepung. Hasil dari penelitian ini berpotensi terciptanya inovasi baru yang mampu diimplementasikan dalam dunia nyata, seperti sistem pemilahan produk cacat menggunakan respon *reject* sehingga dapat meningkatkan kualitas dan efisiensi proses produksi.

2. METODE PENELITIAN

2.1 Objek dan Area Deteksi

Objek penelitian ini menggunakan produk kemasan tepung terigu bogasari segitiga biru pada variasi berat 500 gram. Fokus deteksi berada pada area adhesif di bagian vertikal kemasan. Perbedaan signifikan dengan penelitian sebelumnya selain yang tertera pada bab pendahuluan, juga terletak pada pendekatan pemrosesan gambar. Dalam penelitian ini, dilakukan penggunaan citra *grayscale* sebagai *input* gambar untuk mempercepat proses ekstraksi fitur. Pada Gambar 1 berikut merupakan area adhesif kemasan yang dideteksi dan data *input* citra yang akan diproses.



Gambar 1: Area Adhesif Kemasan yang Dideteksi dan *Input* Citra *Grayscale*

2.2 Parameter Metode dan Arsitektur Penelitian

Pemilihan metode dan arsitektur pada penelitian ini merupakan *point* utama sebagai penentuan keberhasilan sistem deteksi. Metode yang diimplementasikan untuk klasifikasi deteksi yakni menggunakan metode *Convolutional Neural Network* atau CNN. *Convolutional Neural Network* merupakan metode dengan jaringan syaraf untuk mengambil keputusan terhadap *hierarki* fitur pada data citra dengan *output* berupa klasifikasi pengenalan [9] [10]. Ciri khas dari metode ini yakni adanya operasi konvolusi pada data *input* untuk mendeteksi fitur penting melalui beberapa lapisan yang kompleks [11]. Selain itu terdapat lapisan *pooling* untuk mereduksi dimensional spasial citra, langkah ini dilakukan untuk mengurangi kompleksitas komputasi dan membantu dalam pembentukan



invariansi terhadap pergeseran posisi objek [12]. Selanjutnya data citra dirubah menjadi *neuron* aktif pada lapisan *fully connected layer* untuk dilakukan klasifikasi hasil deteksi [13].

Pada penelitian ini model CNN dirancang dengan arsitektur *UNet-Inception* sebagai hasil kombinasi penggabungan antara arsitektur *UNet* dan *Inception*. Arsitektur *UNet-Inception* dipilih sebagai konstruksi *layer* model CNN karena memiliki struktur *skip connection* yang memungkinkan untuk penggabungan fitur-fitur secara cepat, mampu mengenali detail halus pada pola *pixel* citra, seta arsitektur ini dirancang untuk mengurangi jumlah parameter sehingga dapat menghasilkan peningkatan kecepatan pelatihan dan inferensi model. Selain itu, arsitektur ini memiliki fleksibilitas yang tinggi untuk menangani berbagai tantangan pemrosesan citra seperti segmentasi dan kompleksitas klasifikasi. Berikut merupakan visualisasi arsitektur *UNet-Inception* dan pemrosesan klasifikasi pada penelitian ini, sedangkan pada Gambar 2 berikut merupakan Arsitektur *UNet-Inception* yang dikembangkan oleh peneliti.

```
# Definisi input shape
input_shape = (200, 200, 3)
input_layer = Input(shape=input_shape)

# Encoding (UNet) dan Decoding (UNet)
conv1 = Conv2D(64, 3, activation='relu', padding='same')(input_layer)
pool1 = MaxPooling2D(pool_size=(2, 2))(conv1)
up_conv1 = Conv2D(64, 2, activation='relu', padding='same')(UpSampling2D(size=(2, 2))(pool1))
concat1 = concatenate([conv1, up_conv1], axis=-1)
# Inception
inception1 = Conv2D(128, 1, activation='relu')(concat1)
inception1 = Conv2D(128, 3, activation='relu', padding='same')(inception1)
pool2 = MaxPooling2D(pool_size=(2, 2))(inception1)

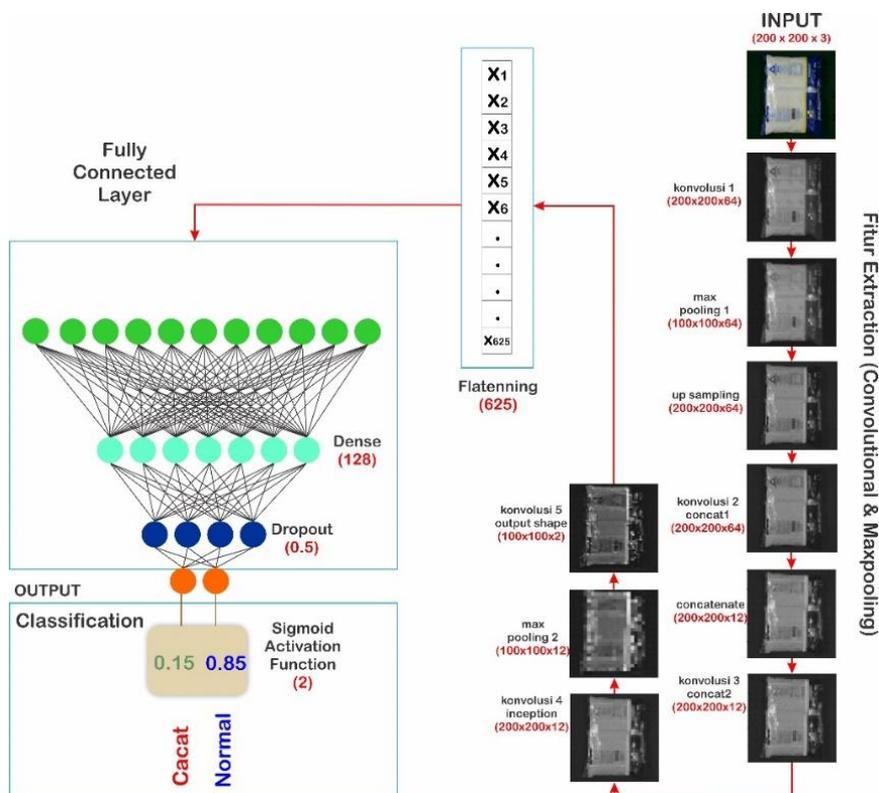
# Output Layer
num_classes = 2 # Misalnya, 2 kategori: cacat dan normal
output_layer = Conv2D(num_classes, 1, activation='softmax')(pool2)
model = Model(inputs=input_layer, outputs=output_layer)
model.summary()
```

Layer (type)	Output Shape	Param #	Connected to
input_1 (InputLayer)	(None, 200, 200, 3)	0	None
conv2d (Conv2D)	(None, 200, 200, 64)	1792	input_1[0][0]
max_pooling2d (MaxPooling2D)	(None, 100, 100, 64)	0	conv2d[0][0]
up_sampling2d (UpSampling2D)	(None, 200, 200, 64)	0	max_pooling2d[0][0]
conv2d_1 (Conv2D)	(None, 200, 200, 64)	16448	up_sampling2d[0][0]
concatenate (Concatenate)	(None, 200, 200, 128)	0	conv2d[0][0], conv2d_1[0][0]
conv2d_2 (Conv2D)	(None, 200, 200, 128)	16512	concatenate[0][0]
conv2d_3 (Conv2D)	(None, 200, 200, 128)	147584	conv2d_2[0][0]
max_pooling2d_1 (MaxPooling2D)	(None, 100, 100, 128)	0	conv2d_3[0][0]



```
conv2d_4 (Conv2D) (None, 100, 100, 2) 258 ['max_pooling2d_1[0][0]']
-----
Total params: 182,594
Trainable params: 182,594
Non-trainable params: 0
```

Gambar 2: Arsitektur *UNet-Inception* yang Dikembangkan Oleh Peneliti

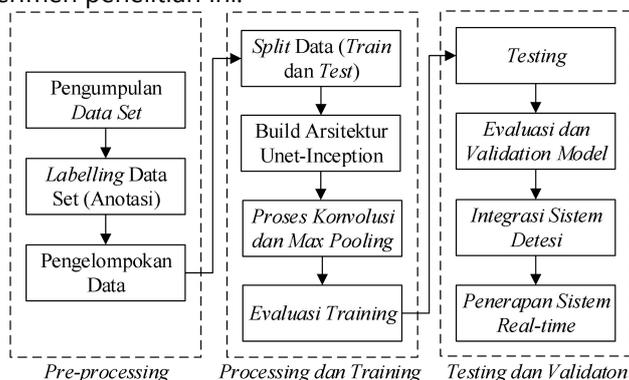


Gambar 3: Pemrosesan Ekstraksi dan Klasifikasi Citra dengan *UNet-Inception* CNN

Berdasarkan Gambar 3 tersebut menunjukkan pemrosesan ekstraksi dan klasifikasi citra terhadap beberapa proses pengolahan citra dengan *Convolutional Neural Network* (CNN) yang meliputi *fitur extraction*, *flattening*, *fully connected layer*, dan *classification*.

2.3 Perancangan Eksperimen Penelitian

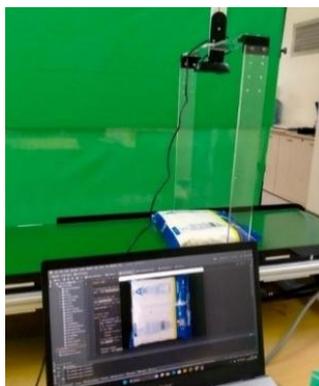
Sub bab ini dilakukan untuk mengetahui alur perancangan dan langkah eksperimen penelitian. Gambar 4 berikut menunjukkan alur eksperimen penelitian ini.



Gambar 4: Perancangan Eksperimen Penelitian

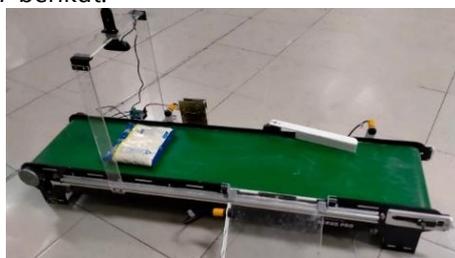


Berdasarkan Gambar 4, Langkah-langkah penelitian ini terdiri dari beberapa tahapan penting. Pertama, pengambilan *dataset* produk, teknik pengumpulan data dilakukan diatas mekanik conveyor dengan *web camera* C310 pada *capture* produk dengan jarak ketinggian 30 cm. Teknik pengambilan *dataset* disajikan pada Gambar 5 berikut.

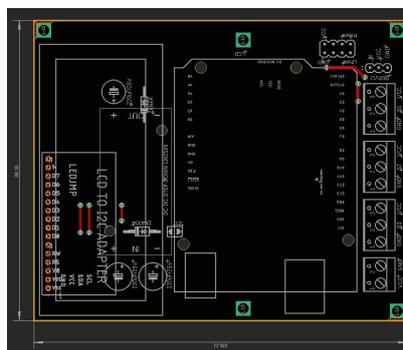


Gambar 5: Teknik Pengambilan *Dataset*

Selanjutnya data akan dianotasi untuk memberikan *label* sebagai identitas pada setiap entri data. Kemudian, data akan dikelompokkan berdasarkan kategorinya dan diikuti dengan pembagian *dataset* menjadi data *training* dan data *testing*. Selanjutnya melibatkan penyusunan arsitektur *UNet-Inception* CNN serta proses ekstraksi fitur menggunakan konvolusi dan *pooling*. Evaluasi pada tahap pelatihan dilakukan untuk mengamati kinerja model berdasarkan akurasi training yang dicapai. Setelah tahap pelatihan, model akan diuji melalui tahapan pengujian untuk mengukur kemampuan dan respons model terhadap data baru. Evaluasi dan validasi model yang telah dilatih akan dilakukan dengan menggunakan berbagai metrik untuk memahami sejauh mana model mampu mengklasifikasikan dengan benar. Langkah terakhir dalam penelitian ini melibatkan pembuatan sistem integrasi serta implementasi deteksi secara *real-time*. Dengan demikian, sistem dapat memberikan respon secara otomatis dan tepat terhadap data cacat pada kemasan produk tepung terigu. Perancangan mekanik dan desain rangkaian disajikan pada Gambar 6 dan Gambar 7 berikut.



Gambar 6: Tampilan Mekanik Conveyor untuk Sistem Deteksi *Realtime*



Gambar 7: Desain Rangkaian PCB



2.4 Perancangan Sistem Sortir Produk

Perancangan sistem sortir dilakukan sebagai aksi *reject* terhadap produk yang terdefinisi cacat hal ini dilakukan sebagai langkah penyempurnaan sistem. Pelaku *reject* dilakukan oleh motor servo ketika mengenali hasil deteksi produk dengan hasil keputusan berupa produk cacat sehingga motor servo akan mengarahkan produk pada area cacat yang berada disamping conveyor. Tahap awal dimulai dengan klasifikasi produk oleh *web camera*. Data hasil deteksi kemudian diproses untuk menganalisis keputusan hasil deteksi berupa kategori cacat atau normal. Tindakan selanjutnya yakni sortir produk, yang melibatkan motor servo untuk mengarahkan produk cacat keluar dari jalur produksi utama. Perancangan sistem sortir dirancang dengan aksi reject motor servo bergerak dengan radius dimensi sebesar 45 derajat dengan waktu reject selama 2 detik pada setiap produk yang terdeteksi cacat. Sistem perhitungan produk cacat dari proses sortir dilakukan konfigurasi total produk yang terbaca menggunakan sensor proximity yang berada pada area produk cacat.

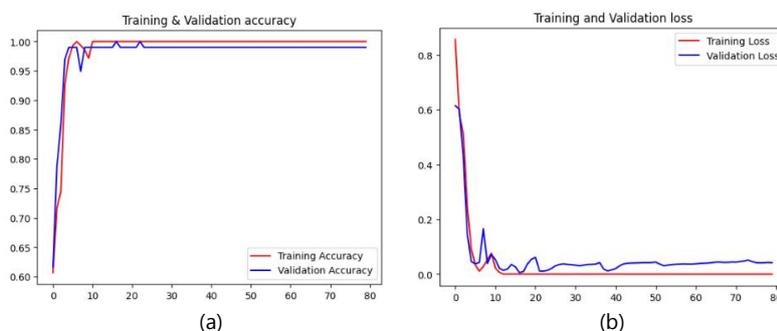
3. HASIL DAN PEMBAHASAN

3.1 Pengujian Training

Tahapan ini dilakukan dengan parameter pengujian pada *ratio training* sebesar 90%, *input shape* 200x200, total *batch size* sebanyak 20, dan penambahan konstruksi arsitektur *UNet-Inception* pada model CNN dengan *layer* konvolusi sebanyak 5 *layer*, *pooling layer* sebanyak 2 *layer*, *up sampling* 1 *layer*, serta *concatenate* sebanyak 1 *layer*. Dengan total *epochs* pada pembelajaran model sebanyak 80 *epochs*. Pada tahapan telah didapatkan hasil bahwa adanya arsitektur *UNet-Inception* pada model CNN menghasilkan nilai *predict* yang lebih baik. Hasil perbandingan *training* model CNN dengan dan tanpa menggunakan arsitektur *UNet-Inception* dapat dilihat pada Tabel 1, sedangkan pada Gambar 8 dan Gambar 9 menunjukkan pola grafik *training* model dan *confusion matriks* yang dihasilkan.

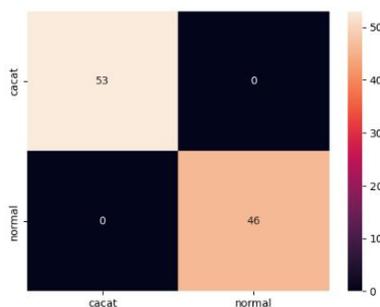
TABEL 1: PERBANDINGAN HASIL TRAINING CNN MENGGUNAKAN ARSITEKTUR UNET-INCEPTION

	<i>Training Accuracy</i>	<i>Training Loss</i>	<i>Validation Accuracy</i>	<i>Validation Loss</i>
Model Tanpa Arsitektur UNet-Inception	71,47%	18,53%	70,77%	23,12%
Model Dengan Arsitektur UNet-Inception	98,39%	8,44%	98,03%	7,66%



Gambar 8: (a) Hasil Training dan Validation Accuracy dengan UNet-Inception, (b) Hasil Training dan Validation Loss UNet-Inception

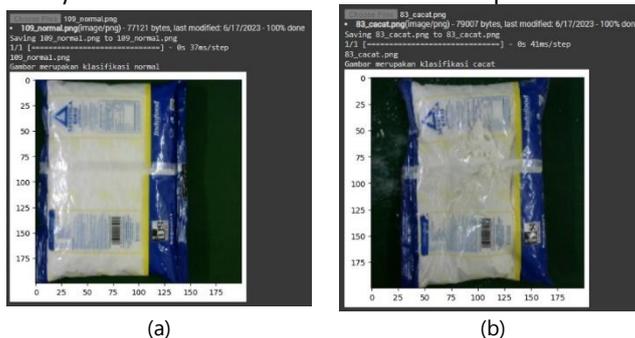




Gambar 9: Hasil *Confusion Matrix*s pada Model dengan arsitektur *UNet-Inception*

3.2 Pengujian *Testing*

Pada pengujiannya, dilakukan percobaan dengan menginput *image* secara *random* diluar gambar *dataset* yang telah dikumpulkan. Data *testing* yang diujikan sebanyak 10% atau sebanyak 30 data *testing* yang terdiri atas 15 data *sample* cacat dan 15 data *sample* normal. Gambar 10 berikut merupakan hasil *testing* model dengan arsitektur.



Gambar 10: (a) *Testing* Produk Normal, (b) *Testing* Produk Cacat

TABEL 2: HASIL *TESTING* MENGGUNAKAN ARSITEKTUR *UNET-INCEPTION*

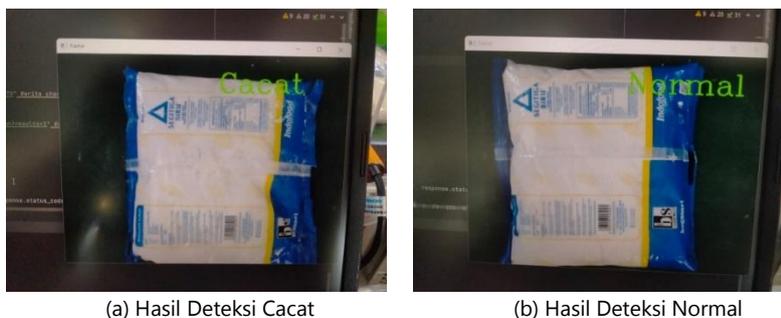
	Total Data yang diujikan	Total Deteksi Benar	Total Deteksi Salah	Akurasi Keberhasilan
Data cacat	15	13	2	86,67%
Data Normal	15	14	1	93,34%
Akurasi Keberhasilan Rata-rata:				90,00%

Berdasarkan pengujian *testing* yang dilakukan pada Tabel 2, didapatkan hasil bahwa total kebenaran deteksi *sample* cacat sebanyak 13 data dari 15 data yang diujikan, sedangkan pada data normal terdefinisi benar sebanyak 14 data dari 15 data *testing* yang diujikan, sehingga diperoleh akurasi rata-rata keberhasilan *testing* mencapai 90,00%.

3.3 Pengujian Sistem Deteksi *Realtime*

Pengujian deteksi *real-time* bertujuan untuk memastikan bahwa model yang telah dilatih tidak hanya memiliki performa yang baik dalam pengujian standar, tetapi juga mampu bekerja secara efektif dalam menghadapi tantangan pengenalan setiap pola *sample* produk yang bervariasi. Dalam konteks deteksi cacat kemasan, pengujian deteksi *real-time* sangatlah penting karena memberikan gambaran bagaimana model mampu saat diterapkan pada sistem ketika alat dioperasikan. Pada pengujiannya dilakukan sebanyak 6 *sample*, dengan 3 diantaranya merupakan produk cacat dan 3 *sample* lainnya adalah produk normal. Setiap sampel diuji sebanyak lima kali untuk memastikan konsistensi hasil. Gambar 11 berikut merupakan tampilan hasil deteksi *sample* cacat dan normal.





Gambar 11: Hasil Sistem Deteksi

TABEL 3: PENGUJIAN SISTEM DETEKSI *REAL-TIME*

Sample ke-	Kategori Data Aktual yang Diujikan	Hasil Prediksi		Akurasi Deteksi
		Total Salah Deteksi	Total Benar Deteksi	
1	cacat	0	5	100%
2	cacat	1	4	80%
3	cacat	0	5	100%
4	normal	0	5	100%
5	normal	1	4	80%
6	normal	0	5	100%
Akurasi Keberhasilan Rata-rata:				93,34%

Berdasarkan hasil pengujian deteksi *real-time* sebagaimana yang telah tertera pada Tabel 3, dimana dilakukan pengujian pada 6 *sample* produk, didapatkan hasil akurasi keberhasilan rata-rata yakni sebesar 93.34%.

3.4 Pengujian Sistem Deteksi Berdasarkan Panjang Bercak Tepung

Pengujian sistem deteksi berdasarkan panjang bercak dibuat untuk menganalisis sejauh mana model yang dibuat dapat mendeteksi dan mengenali detail-detail halus seperti bercak tepung yang keluar pada kategori produk cacat. Dalam proses pengujian, parameter yang diuji adalah panjang bercak tepung yang keluar pada area adhesif kemasan. Variabel yang diujikan meliputi variasi panjang bercak, mulai dari ketiadaan bercak pada produk yang cacat hingga bercak dengan panjang 1 cm, 2 cm, 3 cm, 5 cm, dan 7 cm. Setiap *sampel* diuji sebanyak lima kali untuk memastikan konsistensi hasil.

Prosedur pengujian melibatkan pengukuran panjang bercak tepung yang muncul pada area adhesif kemasan menggunakan mistar. Hal ini dilakukan untuk mengamati sejauh mana model dapat mengidentifikasi berbagai ukuran bercak dan membedakan antara produk cacat dengan produk normal. Pengukuran panjang bercak tepung ini memberikan data yang relevan untuk evaluasi performa model dalam mendeteksi cacat pada berbagai tingkat keparahan. Tampilan visualisasi pengujian deteksi berdasarkan panjang bercak disajikan pada Gambar 12 dan hasil pengujian disajikan sebagaimana yang tertera pada Tabel 4 berikut.



Gambar 12: Pengujian Hasil Deteksi Berdasarkan Panjang Bercak



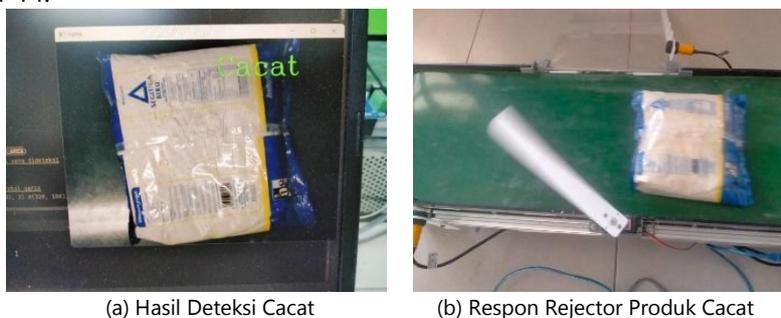
TABEL 4: PENGUJIAN SISTEM DETEKSI BERDASARKAN PANJANG BERCAK

Variasi Panjang Bercak yang Diujikan	Hasil Prediksi		Akurasi Deteksi
	Total Benar Deteksi	Total Salah Deteksi	
Sample tidak keluar bercak	1	4	20%
1 cm	4	1	80%
2 cm	4	1	80%
3 cm	5	0	100%
5 cm	5	0	100%
7 cm	5	0	100%

Berdasarkan data hasil pengujian yang tercatat dalam Tabel 4, didapatkan bahwa sistem mampu mengenali *sampel* produk cacat pada indikasi bercak yang cukup kecil dengan sangat baik. Namun, saat dihadapkan pada *sampel* cacat yang tidak memiliki bercak yang keluar, sistem mengalami kesulitan dalam mengambil keputusan deteksi, karena adanya kesamaan dengan karakteristik produk normal. Hasil pengujian dalam sub-bab ini menunjukkan bahwa sistem mampu melakukan klasifikasi produk dengan sangat baik berdasarkan karakteristik bercak. Semakin panjang bercak yang muncul pada produk cacat, maka semakin tinggi kemungkinan sistem dalam menghasilkan keputusan deteksi yang optimal. Temuan ini juga menunjukkan bahwa hasil pengujian menunjukkan deteksi yang optimal terjadi pada panjang bercak 3 cm, 5 cm, dan 7 cm, dengan akurasi keberhasilan mencapai 100%.

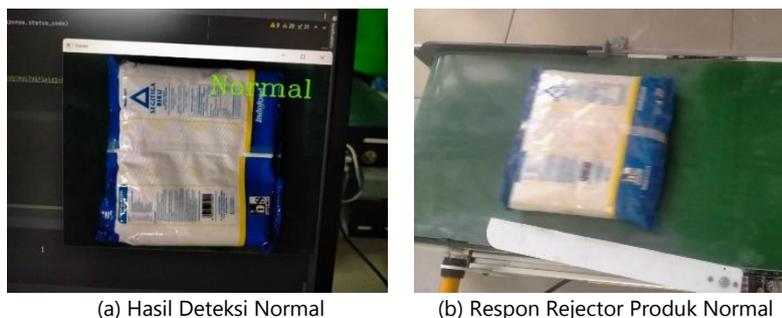
3.5 Pengujian Sistem Deteksi *Realtime* terhadap Respon *Rejector*

Dalam sub-bab pengujian ini, dilakukan evaluasi antara hasil deteksi yang dihasilkan oleh sistem dan respons dari aksi *reject* pada perangkat. Tujuannya adalah untuk menguji sejauh mana respons aksi *reject* sesuai dengan hasil deteksi produk cacat yang dilakukan oleh sistem. Ketika sistem mendeteksi keberadaan produk cacat, respons yang dihasilkan adalah gerakan dari *rejector* yang akan menghalangi pergerakan produk cacat. Hal ini bertujuan untuk mencegah produk cacat melaju ke tahap selanjutnya dalam proses produksi, sehingga dapat meminimalisir potensi bercampurnya produk cacat dan normal yang dapat berdampak pada kualitas produk akhir. Pengujian hubungan hasil deteksi *realtime* dengan aksi *rejector* disajikan sebagaimana yang telah tertera pada Gambar 13 dan Gambar 14.



Gambar 13: Pengujian Hubungan Hasil Deteksi *Realtime* dengan Aksi *Rejector* pada Produk Cacat





Gambar 14: Pengujian Hubungan Hasil Deteksi *Realtime* dengan Aksi Rejector pada Produk Normal

Gambar 13: dan 14: menyajikan hasil deteksi terhadap respon *rejector*. Berdasarkan pengujian yang telah dilakukan, *respons* dari *rejector* diimplementasikan melalui motor servo yang bergerak untuk menghalangi arah gerak conveyor ketika produk cacat terdeteksi. Tindakan ini memungkinkan produk cacat untuk dipisahkan dan dialihkan ke area yang ditentukan untuk produk cacat. Penelitian ini menjalankan pengujian secara acak pada *sampel* uji, dengan total 10 kali percobaan pengujian. Pendekatan ini dilakukan untuk mengidentifikasi serta menganalisis sejauh mana akurasi hasil deteksi yang sesuai dengan *respons* yang dihasilkan oleh *rejector*. Hasil pengujian deteksi terhadap respon *reject* adalah indikasi motor servo yang aktif dengan menghalangi arah gerak conveyor atau "ON" untuk respon deteksi cacat, Di sisi lain, indikasi "OFF" dari motor servo menunjukkan aksi reject terhadap hasil deteksi produk normal. Pengujian sistem deteksi terhadap respon *reject* disajikan pada Tabel 5 berikut.

TABEL 5: PENGUJIAN HASIL DETEKSI DENGAN AKSI REJECT

Kategori <i>Sample Uji</i>	Hasil Deteksi <i>Sample</i>	Respon Reject	Hasil
normal	normal	OFF	Benar
cacat	cacat	ON	Benar
cacat	cacat	ON	Benar
normal	normal	OFF	Benar
cacat	cacat	ON	Benar
normal	normal	OFF	Benar
cacat	cacat	ON	Benar
normal	normal	OFF	Benar
cacat	cacat	ON	Benar
normal	normal	OFF	Benar
Akurasi Keberhasilan:			100%

Berdasarkan pengujian hasil deteksi dengan aksi reject yang tertera pada Tabel 5, hasil yang diperoleh menunjukkan bahwa sistem integrasi ini menghasilkan ketepatan deteksi produk cacat dan normal sebanyak 10 data dengan tingkat akurasi keberhasilan mencapai 100%. Keandalan *respons* aksi *reject* yang presisi dan akurat ini menunjukkan bahwa sistem sortir mampu memilah produk cacat dengan efektif dan konsisten serta mampu mencegah produk cacat melanjutkan ke tahap berikutnya dalam proses produksi

4. KESIMPULAN

Berdasarkan tahapan analisis dan pembahasan yang telah dilakukan, secara keseluruhan sistem deteksi ini memberikan indeks klasifikasi dalam dua kategori utama, yaitu kelas "cacat" dan "normal". Melalui serangkaian uji coba dan evaluasi, hasil penelitian ini dapat disimpulkan sebagai berikut:

1. Arsitektur *UNet-Inception* yang telah dikembangkan oleh peneliti memiliki konstruksi *layer* konvolusi sebanyak 5 *layer*, serta 2 *layer pooling* untuk proses ekstraksi dan reduksi fitur. Selain itu, terdapat 1 *layer up sampling* untuk meningkatkan dimensi data, dan 1 *layer pola concatenate* untuk menggabungkan informasi. Pada tahap pengembangan, peneliti juga menambahkan *layer convolutional*



- inception* (Conv2D) dengan 128 *neuron* di dalamnya, serta menerapkan *layer Up Sampling* dua dimensi dengan ukuran 2x2. Konfigurasi yang diciptakan oleh peneliti ini bertujuan untuk menghasilkan representasi fitur yang lebih kompleks dan akurat dalam memproses gambar.
2. Adanya penambahan dan modifikasi arsitektur *UNet-Inception* pada model CNN telah memberikan pengaruh signifikan dalam memperbaiki akurasi *training*. Pada pengujiannya, model dengan arsitektur *UNet-Inception* berhasil mencapai tingkat akurasi yang lebih tinggi daripada model tanpa arsitektur *UNet-Inception* dengan perbandingan yakni 93,34% berbanding 86,67%. *Testing* dengan Arsitektur *UNet-Inception* menghasilkan akurasi sebesar 90%.
 3. Penelitian ini menemukan temuan baru bahwa Arsitektur *UNet-Inception* memberikan kontribusi yang positif dalam meningkatkan kemampuan model dalam mengenali pola-pola penting dalam implementasi nyata. Hal tersebut dibuktikan telah optimalnya sistem deteksi *real-time* dalam klasifikasi produk dengan akurasi mencapai 93,34%. Selain itu penelitian ini menunjukkan bahwa sistem mampu melakukan klasifikasi produk dengan sangat baik berdasarkan karakteristik bercak pada panjang bercak 3 cm, 5 cm, dan 7 cm, yang menghasilkan akurasi keberhasilan mencapai 100%.
 4. Sistem integrasi dalam bentuk sortir yang telah diimplementasikan berhasil memberikan *respons* aksi *reject* yang sesuai dengan hasil deteksi produk cacat. Dalam pengujian yang dilakukan, sistem integrasi ini menghasilkan tingkat akurasi keberhasilan mencapai 100%. Keandalan *respons* aksi *reject* yang presisi dan akurat ini menunjukkan bahwa sistem sortir mampu memilah produk cacat dengan efektif dan konsisten serta mampu mencegah produk cacat melanjutkan ke tahap berikutnya dalam proses produksi.

Penelitian ini telah berhasil menghasilkan pengembangan yang signifikan dalam dua aspek utama, yaitu konfigurasi model *Convolutional Neural Network* (CNN) dengan menggunakan arsitektur *UNet-Inception*, serta merancang *respons* aksi *reject* dalam sistem deteksi. Keberhasilan ini menggarisbawahi efektivitas dan kehandalan integrasi sistem dalam melakukan pemisahan produk cacat secara akurat, yang pada gilirannya berpotensi meningkatkan kualitas dan efisiensi keseluruhan dalam lingkungan produksi. Dimasa mendatang, Peneliti berharap adanya kelanjutan studi kelayakan guna menerapkan solusi yang telah dikembangkan dalam skala industri yang lebih luas. Melalui studi kelayakan yang komprehensif, Diharapkan dapat terciptanya studi kelayakan yang terfokus pada kerangka kerja industri secara terperinci, potensi penggunaan solusi ini dapat diwujudkan dengan efisien, efektif, optimal, dan *performative*. Sehingga *output* dari penelitian ini dapat berdampak positif dalam menunjang kualitas dan produktivitas di dalam proses produksi industri.

DAFTAR PUSTAKA

- [1] S. Setyo and E. Waziroh, *Teknologi Pengolahan Tepung Terigu dan Olahannya di Industri*. Universitas Brawijaya PRESS, 2019.
- [2] D. T. Utomo, "ALTERNATIF PENERAPAN TEKNOLOGI INFORMASI DALAM PENENTUAN SUPPLIER INDUSTRI MANUFAKTUR BERBASIS BILL of MATERIAL DAN GROUP TECHNOLOGY," *Dr. Diss. Politek. Negeri Jember*, 2021.
- [3] Widianingsih, D. Tri, W. Rahayu, and H. Sulistiono, "Perancangan Sistem Informasi Penyewaan Kamera Digital pada Allazza Rental Berbasis Java," *J. Ris. dan Apl. Mhs. Inform.*, vol. 04, no. 2, pp. 240–247.
- [4] Racellita and Megawati, "Pengaruh Kualitas Produk, Harga, Citra Merek Dan Promosi Terhadap Minat Beli Konsumen Terhadap Operator Kartu Seluler Tri (3) Di Palembang," *Publ. Ris. Mhs. Manaj.*, vol. 3, no. 1, pp. 78–91, 2021.
- [5] Richo, R. Y. Adhitya, M. K. Hasin, M. Syai, and E. Setiawan, "Analisis Pengaruh Optimizer pada Model CNN untuk Identifikasi Cacat pada Perekat Kemasan," *J. SISFOTENIKA*, vol. 13, no. 2, pp. 217–229, 2023.
- [6] R. A. F. CHANIAGO, "KOMBINASI ARSITEKTUR UNET-INCEPTION DAN DROPOUT DALAM PROSES SEGMENTASI CITRA TIGA DIMENSI TUMOR OTAK DARI MAGNETIC RESONANCE IMAGING," 2023.
- [7] J. Aprilyanto and Yohannes, "IMPLEMENTASI ARSITEKTUR VGG-UNET DALAM MELAKUKAN SEGMENTASI KERETAKAN PADA CITRA BANGUNAN," *MDP STUDENT Conf. 2023*, pp. 257–264, 2023.
- [8] U. Ungkawa and G. A. L. Hakim, "Klasifikasi Warna pada Kematangan Buah Kopi Kuning menggunakan Metode CNN Inception V3," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 11, no. 3, pp. 731–743, 2023.
- [9] J. Christian, S. Iskandar, and A. Idrus, "Introduction to Citrus Fruit Ripens Using the Deep Learning Convolutional Neural Network (CNN) Learning Method Pengenalan Kematangan Buah Jeruk Dengan Metode Pembelajaran Deep Learning Convolutional Neural Network (CNN)," vol. 2, no. 3, pp. 459–470, 2023.
- [10] N. Puspitasari, K. Nugroho, and K. Hadiono, "Usability Deteksi Tumor Otak Menggunakan Metode DNN (Deep Neural Network) Berbasis Citra Medis Pada DICOM Usability of Brain Tumor Detection Using the DNN (Deep Neural Network) Method Based on Medical Image



- on DICOM," *CESS (Journal Comput. Eng. Syst. Sci.*, vol. 8, no. 2, pp. 619–632, 2023.
- [11] K. Azmi, S. Defit, and S. Sumijan, "Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat," *J. Unitek*, vol. 16, no. 1, pp. 28–40, 2023, doi: 10.52072/unitek.v16i1.504.
- [12] S. Sheila, M. K. Anwar, A. B. Saputra, F. R. Pujianto, and I. P. Sari, "Deteksi Penyakit pada Tanaman Padi Menggunakan Pengolahan Citra Digital dengan Metode Convolutional Neural Network," *J. Electr. Syst. Control Eng.*, vol. 6, no. 2, pp. 98–108, 2023, doi: 10.31289/jesce.v6i2.7930.
- [13] W. Luo, G. Zhang, Q. Shao, X. Li, Z. Wang, and X. Zhu, "Highly Accurate and Reliable Tracker for UAV-Based Herd Monitoring," 2023, doi: 10.20944/preprints202306.1669.v1.

