

# KLASIFIKASI KUALITAS HASIL PRODUKSI TAHU PUTIH MENGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK

Irwan Rahmadani<sup>1</sup>, Muqimuddin<sup>2</sup>, Christopher Davito Prabandewa Hertadi<sup>3</sup>, dan Bowo Nugroho<sup>4</sup>

<sup>1,2,3</sup>Teknik Industri, Institut Teknologi Kalimantan

<sup>4</sup>Informatika, Institut Teknologi Kalimantan

E-mail: 12191039@student.itk.ac.id<sup>1)</sup>, muqimuddin@lecturer.itk.ac.id<sup>2)</sup>, christopher.davito@lecturer.itk.ac.id<sup>3)</sup>,  
bowo.nugroho@lecturer.itk.ac.id<sup>4)</sup>

## ABSTRAK

Penelitian ini mengembangkan sebuah model *Convolutional Neural Network* (CNN) untuk melakukan klasifikasi kategori mutu tahu berdasarkan citra digital dan menentukan grid produk tahu berdasarkan kategori mutunya. Tahapan penelitian ini meliputi pengambilan sampel data, pelabelan data, preprocessing citra, pembuatan model CNN, training model CNN, evaluasi model CNN dan visualisasi kategorisasi. Sampel data yang digunakan dalam penelitian ini terdiri dari 600 citra tahu yang terbagi menjadi tiga kategori mutu, yaitu mutu A, B, dan C. Peneliti menggunakan metode pembaharuan stokastik (Stochastic Gradient Descent) dengan learning rate 0.001, dan fungsi aktivasi ReLU. Hasil pengembangan menunjukkan bahwa model kedua keseluruhan bentuk memiliki tingkat performansi dan validasi akurasi yang lebih tinggi sebesar 100 % dibandingkan dengan model pertama tampak permukaan sebesar 77%. Model kedua memiliki arsitektur yang lebih kompleks dan lebih sesuai dengan karakteristik deteksi keseluruhan bentuk pada tahu. Dengan pengembangan model CNN ini, diharapkan industri tahu dapat meningkatkan efisiensi dalam penentuan kualitas tahu dan harga jual yang sesuai. Implementasi teknologi ini memungkinkan kategorisasi mutu tahu yang akurat dan objektif berdasarkan citra digital, yang dapat mengurangi ketergantungan pada penilaian manual.

**Kata Kunci:** *Neural Network, Image Processing, Kategorisasi Mutu, Deteksi kualitas, Hasil Produksi*

## 1. PENDAHULUAN

Kualitas produk memiliki pengaruh penting dalam keputusan pelanggan saat memilih produk. Kualitas produk juga merupakan faktor kunci bagi perusahaan untuk dapat bertahan dalam persaingan industri yang ketat (Ibrahim & Thanwil, 2019). Untuk memenuhi kepuasan pelanggan, perusahaan harus memberikan produk dengan kualitas yang baik. Perusahaan harus memperhatikan kebutuhan dan keinginan pelanggan karena kualitas produk ini sebenarnya ditentukan berdasarkan pada pelanggan itu sendiri. Jika produk yang dihasilkan tidak sesuai dengan keinginan pelanggan akan berdampak pada pabrik atau industri tersebut tidak akan mampu bertahan (Nugroho et al., 2020).

Badan Pusat Statistik (BPS) mencatat, rata-rata konsumsi tahu dan tempe per kapita di Indonesia sebesar 0,304 kilogram (kg) setiap minggu pada 2021. Angka tersebut naik 3,75% dibanding tahun sebelumnya yang sebesar 0,293 kg setiap minggu. Secara rinci, rata-rata konsumsi per kapita untuk tahu sebesar 0,158 kg setiap minggunya pada 2021. Jumlah tersebut naik 3,27% dibanding 2020 yang sebesar 0,153 kg setiap minggu. Sementara, rata-rata konsumsi per kapita untuk tempe sebesar 0,146 kg setiap minggu. Jumlahnya meningkat 4,29% dibanding tahun sebelumnya yang sebanyak 0,146 kg (BPS, 2023)

Deteksi kualitas pada produsen tahu saat ini masih menggunakan metode tradisional yaitu menggunakan indra mata. Jumlah produksi dengan kuantitas tinggi mengakibatkan klasifikasi sulit dilakukan dengan cara aini sehingga klasifikasi belum dapat dilakukan secara optimal. Dampak dari hal ini yaitu tahu relative dipasarkan dipasar tradisional. Sebab pasar modern memerlukan jaminan mutu produk yang baik. Oleh karena itu masalah ini perlu perhatian untuk ditangani.

Penggunaan teknologi kecerdasan buatan atau artificial intelligence (AI) sudah mesti dapat menjawab permasalahan ini. Jumlah produksi yang banyak sedangkan perlu melakukan peningkatan jaminan mutu produk sebelum menuju pasar dapat dilakukan oleh produsen dengan pemanfaatan teknologi ini. Beberapa penelitian terdahulu sudah melakukan pemanfaatan model teknologi antara lain deteksi kecacatan permukaan kulit manggis (Marifatul Azizah et al., 2018) yang mana menggunakan *Convolutional Neural Network* (CNN) sebagai algoritmen deteksi. Penelitian lainnya yang menggunakan CNN adalah klasifikasi citra kualitas bibit kelapa sawit dengan akurasi 95% (Oktafanda, 2022). Penelitian lain yang menggunakan CNN untuk deteksi dan klasifikasi citra sebagai berikut: (Chen et al., 2024; Du et al., 2023; Duan et al., 2024; Ehtisham et al., 2024; Han et al., 2024; Passos & Mishra, 2023; Tetard et al., 2023; Wang & Yin, 2024; Zhu et al., 2023)

Penelitian ini juga berupaya melakukan hal yang sama yaitu menggunakan CNN sebagai algoritma deteksi untuk tahu, yang mana belum pernah dilakukan oleh peneliti sebelumnya. Dengan adanya penelitian ini, dapat menjadi rujukan model deteksi kualitas tahu yang mampu pendukung dalam peeningkatan nilai jual tahu yang selanjutnya meningkatkan pengembangan industri kecil..

## 2. RUANG LINGKUP

Adapun ruang penelitian ini antara lain sebagai berikut:

1. Mengimplementasikan algoritma Convolutional Neural Network dalam mengklasifikasi mutu tahu kedalam 3 kategori.
2. Fokus klasifikasi berdasarkan mutu fisik tahu antara lain warna, bentuk dan kotoran.

## 3. METODOLOGI PENELITIAN

Penelitian ini mengacu pada metode dan tahapan penyelesaian antara lain sebagai berikut:

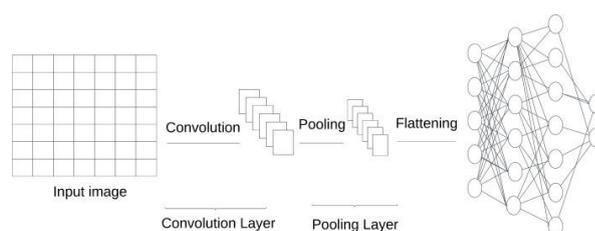
### 3.1 Machine Learning

Machine learning adalah cabang dari kecerdasan buatan yang berkaitan dengan pengembangan algoritma dan model komputer yang dapat belajar dan meningkatkan kinerjanya dari data tanpa diprogram secara eksplisit. Dengan menggunakan teknik dan metode statistik, Machine Learning memungkinkan komputer untuk mengidentifikasi pola, mengambil keputusan, dan membuat prediksi berdasarkan data yang ada. Tujuan utama machine learning adalah untuk mengembangkan model yang dapat mengenali pola dan membuat prediksi yang akurat, sehingga memungkinkan mesin untuk belajar dan beradaptasi dengan data baru untuk memecahkan masalah yang kompleks (Alpaydin, 2021; Dhaka et al., 2021)

### 3.2 Convolutional Neural Network

CNN (*Convolutional Neural Network*) adalah arsitektur jaringan syaraf tiruan khusus untuk pemrosesan data visual. Dengan lapisan konvolusi, pooling, dan fully connected, CNN mampu mengenali pola dan mengekstraksi fitur dari gambar serta jenis file lain yang mendukung proses pengambilan ekstraksi data (Fadlia & Kosasih, 2019). Proses Konvolusi pada CNN diperlihatkan pada Gambar 1. Kelebihan CNN:

- 1) Dapat secara otomatis mengekstraksi ciri penting dari setiap citra tanpa bantuan manusia.
- 2) Lebih efisien dibandingkan metode neural network lainnya terutama untuk memori dan kompleksitas (Li et al., 2022).



Gambar 1. Proses Konvolusi CNN

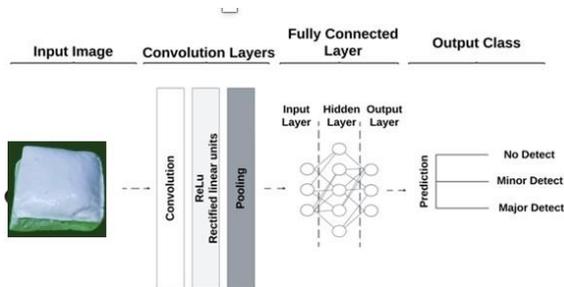
### 3.3 Tahapan Klasifikasi

Metode yang digunakan dalam penelitian ini menggunakan pendekatan *Convolutional Neural Network* (CNN) untuk deteksi dan kategorisasi mutu tahu putih. Metode tersebut melibatkan beberapa langkah-langkah yang meliputi pengumpulan data, preprocessing data, desain arsitektur CNN, pelatihan model, validasi model, pengujian model, analisis hasil dan visualisasi kategori klasifikasi.

1. Pengumpulan Data: Kumpulkan dataset gambar yang berisi model-model dengan variasi dalam hal bentuk, warna, dan kadar kotoran tampak.
2. Anotasi Data: Anotasikan dataset dengan menandai area-area yang mewakili bentuk model, warna model, dan tingkat kotoran pada gambar-gambar tersebut.
3. Preprocessing Data: Lakukan preprocessing pada dataset Anda, seperti resizing gambar ke ukuran yang sama, normalisasi intensitas piksel, dan pembagian dataset menjadi data pelatihan, validasi, dan pengujian.
4. Pembuatan Arsitektur CNN: Bangun arsitektur *Convolutional Neural Network* (CNN) yang dapat mempelajari dan membedakan antara bentuk model, warna model, dan kadar kotoran tampak. Peneliti menggunakan arsitektur CNN yang sesuai dengan kebutuhan, seperti menggunakan beberapa lapisan konvolusi dan lapisan terhubung sepenuhnya (*Fully Connected layers*).
5. Pelatihan Model: Latih model CNN dengan menggunakan data pelatihan. Selama pelatihan, model akan belajar untuk mengenali pola-pola yang berkaitan dengan bentuk model, warna model, dan kadar kotoran tampak.
6. Validasi Model: Evaluasi model CNN menggunakan data validasi yang tidak digunakan selama pelatihan. Hal ini membantu dapat untuk memantau performa model dan melakukan penyesuaian parameter jika diperlukan.
7. Pengujian Model: Gunakan data pengujian yang tidak pernah dilihat oleh model selama pelatihan dan validasi untuk menguji performa model secara objektif. Hitung matrik evaluasi seperti akurasi, presisi, recall, atau F1-score untuk mengukur kinerja model dalam mendeteksi bentuk, warna, dan kadar kotoran tampak.



8. Visualisasi Model: Dengan metode ini, pendekatan CNN digunakan untuk mengatasi tugas deteksi dan kategorisasi mutu tahu putih, yang memungkinkan proses yang lebih otomatis dan efisien dalam penilaian kualitas produk (Nielsen, 2019).



Gambar 2. Deteksi Mutu Tahu Putih

### 3.4 Indikator Parameter Deteksi

Indikator Parameter Deteksi CNN Pada Tahu Putih meliputi warna, bentuk, dan kotoran tampak, dengan menggunakan kombinasi indikator parameter ini, model CNN dapat mempelajari dan mengenali tahu putih secara akurat berdasarkan ciri-ciri warna, bentuk, dan kotoran yang tampak pada objek tersebut.

Tabel 1. Indikator Parameter Deteksi Tahu Putih

Klasifikasi Grid 1	Klasifikasi Grid 2	Klasifikasi Grid 3
Bentuk > 95%	Bentuk 90% - 95%	Bentuk 80% - 85%
Warna > 95%	Warna > 91%-95%	Warna > 85%-90%
Kotoran Tidak Tampak > 98%	Kotoran Tidak Tampak 96%-98%	Kotoran Tidak Tampak 90%-95%

### 3.5 Data Set

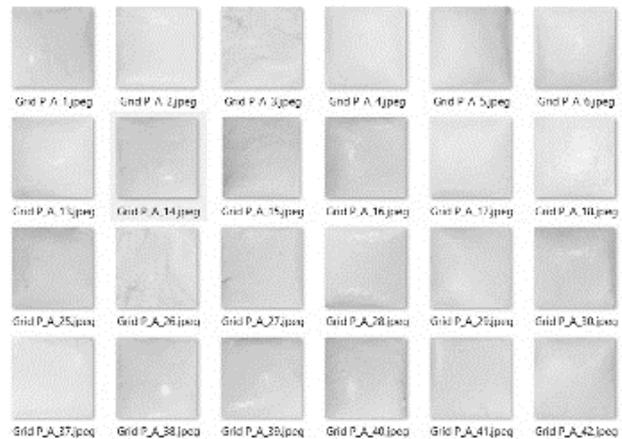
Data set berjumlah 600 data dibagi menjadi dua model pada 1 model berjumlah 300 data set serta dimasukkan kedalam sebuah folder yang telah dilakukan labeling. Adapun sebaran dataset berdasarkan 2 model dapat dilihat pada table 2 berikut:

Tabel 2. Dataset Model

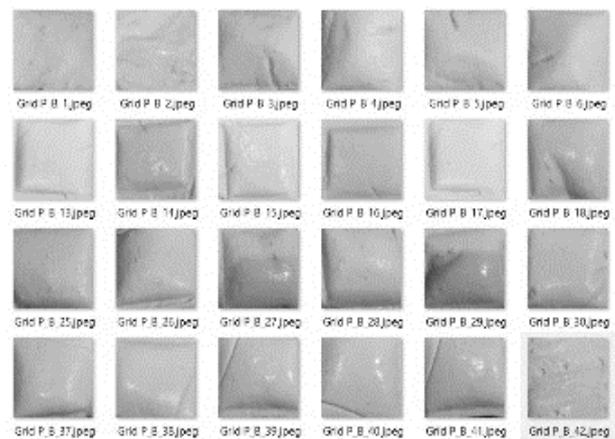
No	Model	Grid	Jumlah Data Set
1	Tampak Permukaan	1	100
		2	100
		3	100
2	Tampak Keseluruhan Bentuk	1	100
		2	100
		3	100

Ada 2 model yang menjadi dataset dalam penelitian ini yaitu model tampak permukaan dan model tampak keseluruhan. Gambar 3. Dan gambar 4. menampilkan contoh dari data yang digunakan dalam penelitian ini. Pada gambar 3 menunjukkan data set yang menampilkan satu sisi dari tahu. Pada Gambar 4. Menggunakan data set dengan menggunakan citra satu yang tampak dari

lebih dari satu sisi. Kedua data set ini diharapkan memberikan ciri yang berbeda sehingga dapat memberikan model dengan akurasi yang berbeda pula sebagai perbandingan.



Grid 1

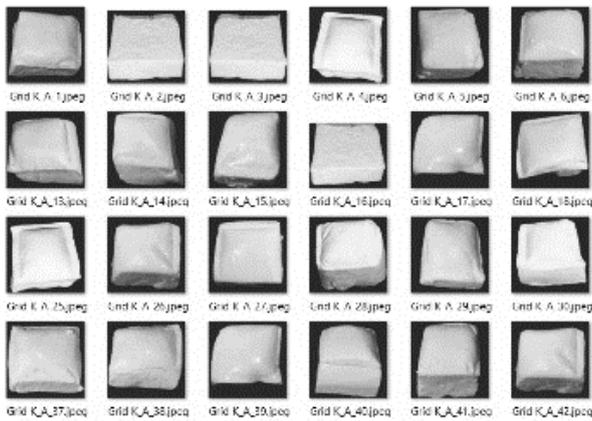


Grid 2

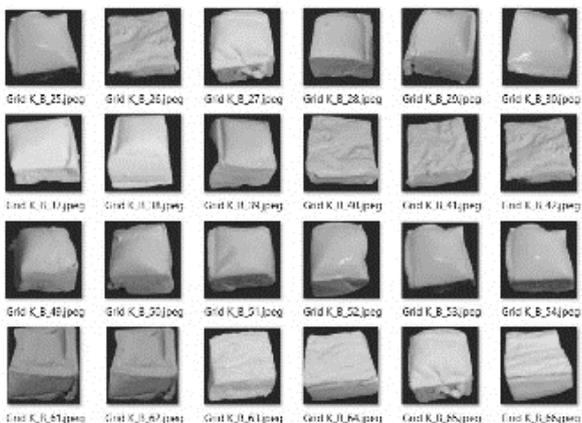


Grid 3

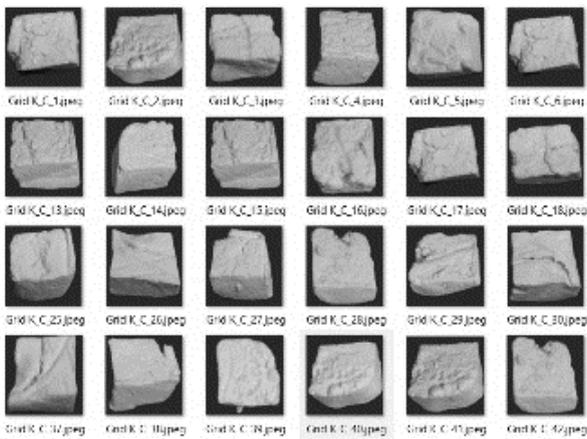
Gambar 3. Data set Model 1 (Tampak Permukaan)



Grid 1



Grid 2



Grid 3

Gambar 4. Data set Model 2 (Tampak Keseluruhan Bentuk)

#### 4. HASIL DAN PEMBAHASAN

Hasil pengembangan model kemudian data diuji berdasarkan dataset yang telah ditentukan, selanjutnya dihasilkan pembahasan antarlain sebagai berikut:

#### 4.1. Hasil Klasifikasi

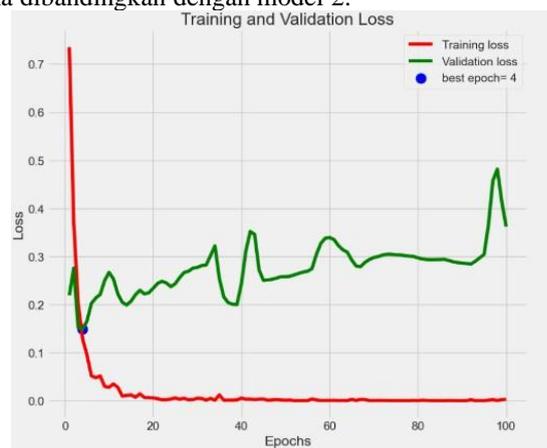
Pada CNN, data training (80%), data testing (10%), dan data validasi (10%) digunakan untuk melatih, menguji performa, dan mengoptimalkan model. Adapun hasil dari pengolahan data dapat dilihat pada tabel 3 berikut:

Tabel 3. Hasil Klasifikasi

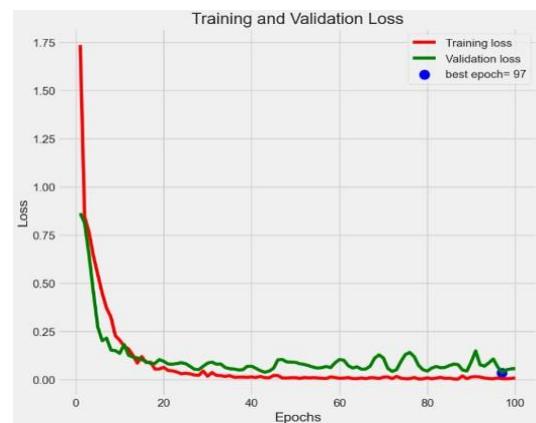
Deteksi	Data Training	Data Testing	Data Validasi
Tampak Permukaan	240	30	30
Tampak Keseluruhan Bentuk	240	30	30

#### 4.2. Performa Model

Gambar 5. menampilkan *training validation loss* merupakan ukuran kesalahan atau kehilangan informasi pada data pelatihan dan validasi selama proses pelatihan model CNN. Semakin rendah nilai loss, semakin baik model mampu menggambarkan data dengan akurat. Pada Gambar 7. nilai loss terlihat lebih tinggi pada model 1 jika dibandingkan dengan model 2.



Model 1

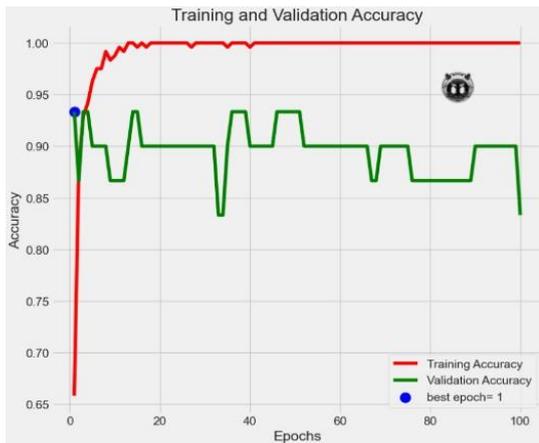


Model 2

Gambar 5. Training dan Validation dan validation loss kedua model



*Training validation accuracy* menunjukkan sejauh mana model CNN mampu memprediksi dengan benar pada data pelatihan dan validasi. Biasanya diukur dalam persentase. Semakin tinggi nilai akurasi, semakin baik kemampuan model dalam mengenali pola dan fitur yang relevan pada data pelatihan dan validasi. Hasil *Training validation accuracy* diperlihatkan pada Gambar 6. *Validation Accuracy* model 1 terlihat lebih tinggi dibandingkan dengan *Validation Accuracy* model 2.



Model 1



Model 2

**Gambar 6. Training and Validation accuracy dan Validation Accuracy kedua model**

### 4.3. Confusion Matrix

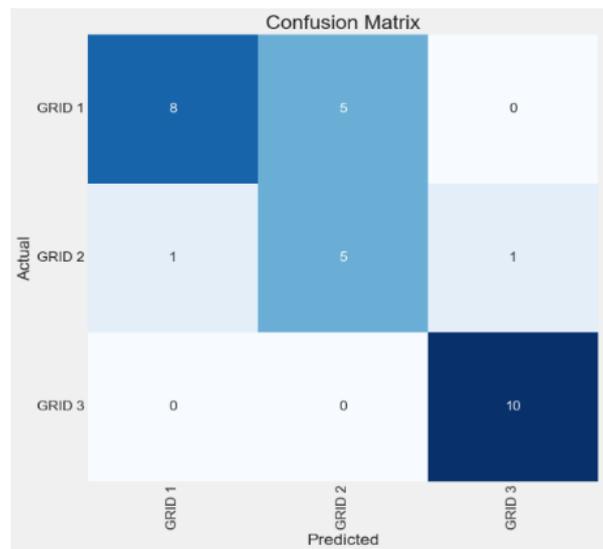
Hasil evaluasi confusion matrik digunakan untuk mengukur kinerja model dalam melakukan klasifikasi pada data uji ditunjukkan pada Tabel 5.

**Tabel 5. Hasil Evaluasi Confusion Matrix**

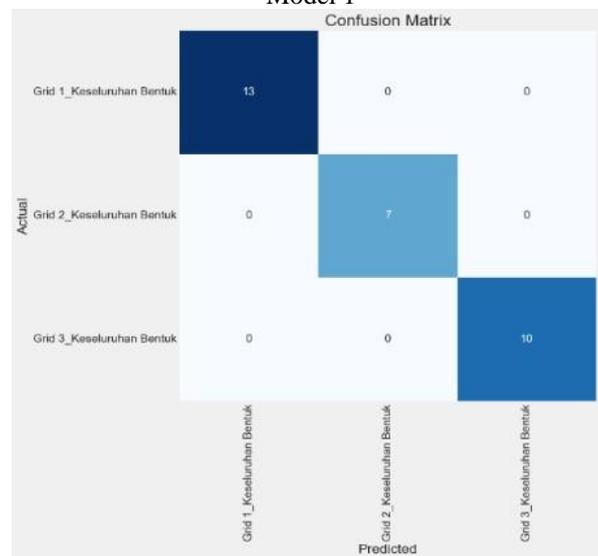
	Prediksi Grid 1	Prediksi Grid 2	Prediksi Grid 3
Grid 1 (Aktual)	TN	FP	FP

Grid 2 (Aktual)	FN	TN	FN
Grid 3 (Aktual)	FN	FP	TN

Dengan *confusion matrix*, peneliti dapat menghitung *True Positive*, *True Negative*, *False Positive*, dan *False Negative*, yang membantu dalam menghitung matrik evaluasi seperti akurasi, presisi, *recall*, dan F1-score. *Confusion matrix* memberikan gambaran tentang sejauh mana model CNN dapat memprediksi kelas yang benar dan mengidentifikasi kesalahan klasifikasi. Gambar 8. merupakan *Confusion Matrix* yang diperoleh.



Model 1



Model 2

**Gambar 8. Confusion Matrix Tampak Permukaan dan Keseluruhan Bentuk**

Diperoleh dari hasil model pertama deteksi permukaan *confusion matrix* didapatkan dari 30 data diperoleh grid 1 delapan data dikategorikan secara akurat 5 dikategorikan sebagai grid selain grid satu, grid

2 lima data dikategorikan secara akurat, dan grid 3 sepuluh data dikategorikan secara akurat. Adapun pada model deteksi kedua tampak keseluruhan bentuk pada setiap grid dapat dikategorikan secara akurat keseluruhan. Hasil dari *confusion matrix* kedua model dapat dilihat secara rinci dari setiap akurasi pada model yang dibangun, hasil ini diperlihatkan pada Tabel 6 dan Tabel 7 berikut

**Tabel 6. Laporan Klasifikasi Model 1**

	Precision	Recall	F1-Score	Support
GRID 1	0.89	0.62	0.73	13
GRID 2	0.50	0.71	0.59	7
GRID 3	0.91	1.00	0.95	10
Accuracy			0.70	30
Macro Avg	0.80	0.77	0.77	30
Weighted Avg	0.81	0.77	0.77	30

**Tabel 7. Laporan Klasifikasi Model 2**

	Precision	Recall	F1-Score	Support
GRID 1				
Keseluruhan Bentuk	1.00	1.00	1.00	13
GRID 2				
Keseluruhan Bentuk	1.00	1.00	1.00	7
GRID 3				
Keseluruhan Bentuk	1.00	1.00	1.00	10
Accuracy			1.00	30
Macro Avg	1.00	1.00	1.00	30
Weighted Avg	1.00	1.00	1.00	30

## 5. KESIMPULAN

Sistem ini berhasil mengklasifikasikan tahu sesuai dengan kriteria target class dan indikator yang telah ditetapkan. Melalui proses pelatihan dan evaluasi model, sistem ini mampu mengenali dan mengklasifikasikan tahu berdasarkan bentuk, warna, dan kadar kotoran. Namun, hasil evaluasi terhadap performa model pertama menunjukkan bahwa akurasi pada tahap pelatihan dan validasi masih belum mencapai tingkat yang diharapkan. Sebaliknya, performa model kedua (dilihat secara keseluruhan) menghasilkan klasifikasi yang lebih akurat. Dalam pelatihan dan validasi menggunakan jaringan syaraf konvolusi (CNN), model secara keseluruhan mencapai tingkat akurasi optimal pada setiap epoch. Performa model juga mencapai tingkat akurasi yang tinggi dan stabil, menunjukkan efektivitas dan kualitas yang baik dari model yang dikembangkan. Evaluasi model CNN terhadap epoch menunjukkan performa yang sangat baik.

## 6. SARAN

Saran untuk penelitian dengan judul atau topik yang me Adapun saran yang dapat diberikan dari hasil penelitian yang dilakukan untuk menjelajahi faktor-faktor lain yang mungkin mempengaruhi masalah yang diteliti. Misalnya, jika penelitian berfokus pada kategorisasi mutu tahu dengan menggunakan convolutional neural network (CNN), peneliti selanjutnya dapat mempertimbangkan faktor-faktor seperti kualitas bahan baku, metode produksi, atau faktor lingkungan yang dapat mempengaruhi mutu tahu. Penelitian ini juga dapat dilanjutkan ke tahap *deployment* kedalam bentuk aplikasi yang dapat langsung digunakan oleh para produsen tahu.

## 7. DAFTAR PUSTAKA

- Alpaydin, E. (2021). *Machine Learning*. The MIT Press. <https://doi.org/10.7551/mitpress/13811.001.0001>
- Azizah, L. M., Umayah, S. F., & Fajar, F. (2018). Deteksi Kecacatan Permukaan Buah Manggis Menggunakan Metode Deep Learning dengan Konvolusi Multilayer. *Semesta Teknika*, 21(2). <https://doi.org/10.18196/st.212229>
- Chen, G., Tian, H., Xiao, T., Xu, T., & Lei, H. (2023). Time series forecasting of oil production in Enhanced Oil Recovery system based on a novel CNN-GRU neural network. *Geoenergy Science and Engineering*, 212528. <https://doi.org/10.1016/j.geoen.2023.212528>
- Dhaka, V. S., Meena, S. V., Rani, G., Sinwar, D., Kavita, K., Ijaz, M. F., & Woźniak, M. (2021). A Survey of Deep Convolutional Neural Networks Applied for Prediction of Plant Leaf Diseases. *Sensors*, 21(14), 4749. <https://doi.org/10.3390/s21144749>
- Du, L., Lu, X., & Li, H. (2023). Automatic fracture detection from the images of electrical image logs using Mask R-CNN. *Fuel*, 351, 128992. <https://doi.org/10.1016/j.fuel.2023.128992>
- Duan, Z., Luo, X., & Zhang, T. (2024). Combining transformers with CNN for multi-focus image fusion. *Expert Systems with Applications*, 235, 121156. <https://doi.org/10.1016/j.eswa.2023.121156>
- Ehtisham, R., Qayyum, W., Camp, C. V., Plevris, V., Mir, J., Khan, Q. Z., & Ahmad, A. (2024). Computing the characteristics of defects in wooden structures using image processing and CNN. *Automation in Construction*, 158, 105211. <https://doi.org/10.1016/j.autcon.2023.105211>
- Fadlia, N., & Kosasih, R. (2019). KLASIFIKASI JENIS KENDARAAN MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN). *Jurnal Ilmiah Teknologi Dan Rekayasa*, 24(3), 207-215. <https://doi.org/10.35760/tr.2019.v24i3.2397>
- Feng, Z., Ji, H., Daković, M., Zhu, M., & Stanković, L. (2023). Analytical interpretation of the gap of



- CNN's cognition between SAR and optical target recognition. *Neural Networks*, 165, 982–986. <https://doi.org/10.1016/j.neunet.2023.06.037>
- Han, Q., Qian, X., Xu, H., Wu, K., Meng, L., Qiu, Z., Weng, T., Zhou, B., & Gao, X. (2024). DM-CNN: Dynamic Multi-scale Convolutional Neural Network with uncertainty quantification for medical image classification. *Computers in Biology and Medicine*, 168, 107758. <https://doi.org/10.1016/j.compbimed.2023.107758>
- Ibrahim, M., & Thawil, S. M. (2019). PENGARUH KUALITAS PRODUK DAN KUALITAS PELAYANAN TERHADAP KEPUASAN PELANGGAN. *Jurnal Riset Manajemen Dan Bisnis (JRMB) Fakultas Ekonomi UNIAT*, 4(1).
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999–7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
- Nugroho, E., Santoso, H. B., & Safi'i, I. (2020). Analisis Pengaruh Kualitas Produk Terhadap Kepuasan Pelanggan. *JURMATIS : Jurnal Ilmiah Mahasiswa Teknik Industri*, 2(2), 106. <https://doi.org/10.30737/jurmatiss.v2i2.953>
- Oktafanda, E. (2022). Klasifikasi Citra Kualitas Bibit dalam Meningkatkan Produksi Kelapa Sawit Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Informatika Ekonomi Bisnis*, 72–77. <https://doi.org/10.37034/infeb.v4i3.143>
- Passos, D., & Mishra, P. (2023). Deep Tutti Frutti: Exploring CNN architectures for dry matter prediction in fruit from multi-fruit near-infrared spectra. *Chemometrics and Intelligent Laboratory Systems*, 243, 105023. <https://doi.org/10.1016/j.chemolab.2023.105023>
- Statistik, B. P. (2023). *Rata-Rata Konsumsi Per Kapita Seminggu Beberapa Macam Bahan Makanan Penting*.
- Tetard, M., Carlsson, V., Meunier, M., & Danelian, T. (2023). Merging databases for CNN image recognition, increasing bias or improving results? *Marine Micropaleontology*, 185, 102296. <https://doi.org/10.1016/j.marmicro.2023.102296>
- Wang, T., & Yin, L. (2023). A hybrid 3DSE-CNN-2DLSTM model for compound fault detection of wind turbines. *Expert Systems with Applications*, 122776. <https://doi.org/10.1016/j.eswa.2023.122776>
- Zhu, Q.-X., Qian, Y.-S., Zhang, N., He, Y.-L., & Xu, Y. (2023). Multi-scale Transformer-CNN domain adaptation network for complex processes fault diagnosis. *Journal of Process Control*, 130, 103069. <https://doi.org/10.1016/j.jprocont.2023.103069>