

## IDENTIFIKASI CACAT RETAK PADA TELUR AYAM RAS DENGAN PENDEKATAN CONVOLUTIONAL NEURAL NETWORK (CNN)

Nalfayo Christian Ratu, Adriana Fanggidae, Yulianto T. Polly

Ilmu Komputer, Universitas Nusa Cendana

Jalan Adisucipto Penfui Kupang, Indonesia

nalfayochristian19@gmail.com, adrianafanggidae@staf.undana.ac.id, yuliantopolly@staf.undana.ac.id

### ABSTRAK

Keretakan pada cangkang telur ayam ras yang tidak terdeteksi secara visual dapat meningkatkan risiko kontaminasi bakteri serta menurunkan kualitas produk selama proses distribusi. Permasalahan utama dalam inspeksi kualitas telur terletak pada metode pemeriksaan manual yang bersifat subjektif, kurang konsisten, dan tidak efisien dalam skala besar. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi otomatis berbasis citra guna mendeteksi keretakan pada cangkang telur ayam ras menggunakan metode Convolutional Neural Network (CNN). Dataset yang digunakan terdiri dari 450 citra RGB telur ayam ras bercangkang cokelat yang diklasifikasikan ke dalam dua kelas, yaitu telur retak dan tidak retak, serta dibagi menjadi data pelatihan, validasi, dan pengujian. Tahap praproses dilakukan melalui teknik augmentasi citra, meliputi rotasi, flipping, penskalaan, penyesuaian kecerahan dan kontras, penambahan noise, serta blur untuk meningkatkan kemampuan generalisasi model. Metode yang diterapkan meliputi penggunaan arsitektur CNN pralatih, yaitu InceptionV3, ResNet50, dan VGG19, dengan evaluasi kinerja berdasarkan confusion matrix yang mencakup akurasi, presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa model InceptionV3 memiliki kinerja terbaik dibandingkan model lainnya pada seluruh metrik evaluasi.

**Kata kunci:** Convolutional Neural Network, Keretakan Telur, Klasifikasi Citra, Deep Learning

### 1. PENDAHULUAN

Kualitas telur ayam ras merupakan salah satu faktor penting dalam industri pangan dan peternakan karena berpengaruh langsung terhadap keamanan dan nilai konsumsi. Salah satu permasalahan yang sering terjadi adalah keretakan pada cangkang telur, khususnya keretakan mikro yang tidak dapat terdeteksi secara kasat mata. Kondisi ini berpotensi meningkatkan risiko kontaminasi bakteri serta menurunkan kualitas telur selama proses penyimpanan dan distribusi. Oleh karena itu, diperlukan metode inspeksi yang akurat dan efisien untuk menjamin kualitas telur secara konsisten, khususnya melalui pendekatan pengolahan citra digital [1].

Namun, proses pemeriksaan telur yang umum dilakukan saat ini masih bersifat manual dan sangat bergantung pada kemampuan visual manusia. Metode ini cenderung subjektif, kurang konsisten, serta memiliki tingkat kesalahan yang tinggi, terutama ketika dilakukan dalam jumlah besar. Beberapa penelitian sebelumnya menunjukkan bahwa pendekatan berbasis *deep learning* mampu meningkatkan akurasi dalam tugas klasifikasi citra dibandingkan metode konvensional [2] [3].

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi otomatis berbasis citra dalam mendeteksi keretakan pada cangkang telur ayam ras. Sistem ini diharapkan mampu meningkatkan akurasi dan efisiensi dalam proses identifikasi telur retak dan tidak retak.

Sebagai solusi, penelitian ini menerapkan metode *Convolutional Neural Network* (CNN) yang

telah terbukti efektif dalam berbagai kasus deteksi retakan dan klasifikasi citra [4], [5], [12].

Pendekatan *transfer learning* digunakan untuk meningkatkan performa model dengan memanfaatkan arsitektur pralatih, sebagaimana telah dibahas dalam beberapa penelitian sebelumnya [13], [14].

Model yang digunakan dalam penelitian ini meliputi InceptionV3, ResNet50, dan VGG19. Data citra diproses melalui tahap praproses dan augmentasi untuk meningkatkan kualitas dan keragaman data. Selanjutnya, model dilatih dan dievaluasi menggunakan metrik kinerja seperti akurasi, presisi, recall, dan F1-score guna menentukan model terbaik dalam melakukan klasifikasi keretakan telur secara otomatis.

### 2. TINJAUAN PUSTAKA

*Convolutional Neural Network* (CNN) merupakan pengembangan dari jaringan saraf tiruan *Multilayer Perceptron* yang dirancang khusus untuk mengolah data dua dimensi, seperti citra digital. CNN mampu mempertahankan informasi spasial citra sehingga lebih efektif dalam melakukan ekstraksi fitur dibandingkan metode *machine learning* konvensional [2] [7].

Arsitektur CNN umumnya terdiri dari *convolution layer*, *pooling layer*, dan *fully connected layer* yang bekerja secara hierarkis untuk mengekstraksi fitur dari tingkat rendah hingga tinggi [8].

CNN telah terbukti unggul dalam berbagai tugas *computer vision*, termasuk klasifikasi citra dan deteksi objek. Keunggulan utama CNN terletak pada kemampuannya melakukan ekstraksi fitur secara

otomatis tanpa memerlukan perancangan fitur manual oleh pengguna [3] [9].

Klasifikasi citra digital merupakan proses pengelompokan citra ke dalam kelas tertentu berdasarkan karakteristik visual yang dimilikinya, seperti tekstur, warna, dan bentuk. Dalam konteks pengolahan citra digital, setiap citra direpresentasikan sebagai matriks dua dimensi yang terdiri dari piksel dengan nilai intensitas tertentu [1] [10][11].

Pendekatan berbasis CNN telah banyak digunakan dalam klasifikasi citra karena mampu menghasilkan akurasi yang lebih tinggi dibandingkan metode berbasis fitur manual. Hal ini disebabkan CNN dapat mempelajari pola kompleks secara langsung dari data citra mentah tanpa memerlukan proses ekstraksi fitur secara eksplisit [3] [12].

Transfer learning merupakan teknik pembelajaran dengan memanfaatkan model CNN yang telah dilatih sebelumnya pada dataset berskala besar, seperti ImageNet, untuk menyelesaikan permasalahan baru dengan dataset yang lebih terbatas [13]. Pendekatan ini memungkinkan proses pelatihan menjadi lebih cepat, meningkatkan stabilitas model, serta mengurangi risiko *overfitting* [14].

Beberapa arsitektur CNN *pretrained* yang umum digunakan antara lain VGG19, ResNet50, dan InceptionV3. Model-model tersebut telah terbukti memiliki kemampuan generalisasi yang baik pada berbagai permasalahan klasifikasi citra, termasuk pada objek dengan variasi permukaan dan kondisi pencahayaan yang kompleks [12] [4].

Penelitian mengenai deteksi keretakan menggunakan CNN telah banyak dilakukan pada berbagai objek. Botta *et al.* membandingkan metode CNN dan Support Vector Machine (SVM) dalam mendeteksi keretakan telur dan menunjukkan bahwa CNN menghasilkan akurasi yang lebih tinggi, yaitu sebesar 95,38% [5].

Penelitian lain oleh Ali *et al.* membandingkan beberapa arsitektur CNN *pretrained* seperti VGG16, VGG19, ResNet50, dan InceptionV3 untuk deteksi retakan pada struktur beton. Hasil penelitian menunjukkan bahwa arsitektur CNN *pretrained* mampu memberikan performa klasifikasi yang stabil meskipun jumlah data relatif terbatas [4].

Pada objek lain, Hendarawan *et al.* menggunakan arsitektur ResNet50 dengan pendekatan *transfer learning* untuk klasifikasi retak pada ban kendaraan dan berhasil mencapai akurasi di atas 90% [6]. Selain itu, Asriani *et al.* membuktikan bahwa arsitektur CNN seperti InceptionV3 dan ResNet50 efektif digunakan untuk klasifikasi retakan pada beton [15].

Berdasarkan penelitian-penelitian tersebut, penggunaan CNN dengan pendekatan *transfer learning* dinilai tepat untuk diterapkan dalam klasifikasi keretakan telur ayam ras, khususnya pada kondisi permukaan telur yang bervariasi dan sebagian kotor.

### 3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental dengan metode *deep learning* berbasis *Convolutional Neural Network* (CNN) untuk mengklasifikasikan keretakan pada telur ayam ras. Tahapan penelitian meliputi pengumpulan data, pra-pemrosesan citra, pelatihan model CNN dengan pendekatan *transfer learning*, serta evaluasi performa model menggunakan metrik berbasis *confusion matrix*.

#### 3.1. Dataset dan Pengumpulan Data

Dataset yang digunakan dalam penelitian ini terdiri dari 450 citra telur ayam ras bercangkang cokelat dalam format RGB (.jpg). Dataset diklasifikasikan ke dalam dua kelas, yaitu telur retak dan telur tidak retak. Data citra diperoleh melalui proses pengambilan gambar secara langsung (data primer). Untuk meningkatkan keragaman sampel, data primer diperbanyak melalui proses augmentasi, seperti rotasi, *shear*, konversi grayscale, *blur*, penambahan *noise*, dan auto-orientasi, sehingga model memiliki variasi data yang cukup [16].

Pengambilan citra dilakukan menggunakan kamera *smartphone* Realme C31 yang memiliki resolusi 13 MP, aperture *f*/2.2, serta resolusi citra maksimum 4128 × 3096 piksel, kamera yang digunakan merupakan lensa tipe *wide*. Pada sebuah kotak pengambilan gambar dengan sumber pencahayaan dari bagian bawah untuk menonjolkan struktur cangkang telur. Setiap telur diletakkan secara acak dengan variasi kondisi permukaan, termasuk telur yang bersih maupun sebagian kotor, guna merepresentasikan kondisi nyata di lapangan.

Dataset dibagi dalam tiga bagian, yaitu data pelatihan (*training*), data validasi (*validation*), dan data pengujian (*testing*) [17].

Rincian pembagian dataset berdasarkan kelas dan jenis data (primer dan sekunder) disajikan pada Tabel 1.

Tabel 1. Pembagian Dataset Citra Telur Ayam Ras

| Jenis Data      | Retak | Tidak Retak | Total |
|-----------------|-------|-------------|-------|
| Data Training   | 100   | 100         | 200   |
| Data Validation | 100   | 50          | 150   |
| Data Testing    | 50    | 50          | 100   |
| Total           | 250   | 200         | 450   |

#### 3.2. Pra-pemrosesan Data

Tahap pra-pemrosesan data dilakukan untuk meningkatkan kualitas citra sebelum digunakan dalam proses pelatihan model *Convolutional Neural Network* (CNN). Pada tahap ini, citra mentah hasil pengambilan gambar terlebih dahulu melalui beberapa proses dasar, meliputi penyesuaian ukuran citra (*image resizing*) dan normalisasi nilai piksel.

Seluruh citra diubah ukurannya menjadi 224 × 224 piksel untuk menyesuaikan kebutuhan arsitektur CNN *pretrained* yang digunakan, yaitu InceptionV3, VGG19, dan ResNet50. Proses *resizing* ini bertujuan

untuk menyamakan dimensi input citra serta mengurangi beban komputasi selama proses pelatihan.

Selanjutnya, dilakukan normalisasi nilai piksel dengan mengubah rentang nilai intensitas dari 0–255 menjadi 0–1. Normalisasi ini bertujuan untuk mempercepat proses konvergensi model dan menjaga stabilitas proses pembelajaran selama pelatihan jaringan saraf.

### 3.3. Augmentasi Data

Untuk meningkatkan keragaman data pelatihan dan mengurangi risiko *overfitting*, penelitian ini menerapkan teknik augmentasi citra pada data pelatihan dan validasi. Augmentasi dilakukan setelah tahap pra-pemrosesan dasar dan tidak diterapkan pada data pengujian.

Teknik augmentasi yang digunakan meliputi rotasi, *flipping*, penskalaan, penyesuaian kecerahan dan kontras, penambahan *noise*, serta *blurring*. Penerapan augmentasi ini bertujuan untuk mensimulasikan variasi kondisi nyata, seperti perubahan orientasi, pencahayaan, dan kondisi permukaan telur, sehingga model CNN memiliki kemampuan generalisasi yang lebih baik.

### 3.4. Arsitektur dan Pelatihan Model CNN

Penelitian ini menerapkan pendekatan *transfer learning* dengan memanfaatkan tiga arsitektur CNN *pretrained*, yaitu InceptionV3, ResNet50, dan VGG19. Model *pretrained* digunakan sebagai *feature extractor*, sementara lapisan klasifikasi disesuaikan untuk tugas klasifikasi biner, yaitu telur retak dan tidak retak.

Proses pelatihan model dilakukan dengan menambahkan lapisan *flatten* dan *fully connected* pada bagian akhir jaringan, kemudian dilatih menggunakan data pelatihan dan divalidasi menggunakan data validasi. Proses pelatihan dilakukan dalam beberapa *epoch* hingga model mencapai performa yang stabil.

### 3.5. Evaluasi Model


Evaluasi kinerja model dilakukan menggunakan data pengujian yang tidak terlibat dalam proses pelatihan. Metode evaluasi yang digunakan adalah *confusion matrix* dengan metrik akurasi, presisi, *recall*, dan *F1-score*. Metrik-metrik tersebut digunakan untuk mengukur kemampuan model dalam mengklasifikasikan telur retak dan tidak retak secara akurat.

Performa ketiga model CNN dibandingkan untuk menentukan arsitektur yang memberikan hasil terbaik dalam mendeteksi keretakan telur ayam ras.

### 3.6. Alur Penelitian

Secara umum, alur penelitian dimulai dari pengumpulan dataset citra telur, dilanjutkan dengan pra-pemrosesan data, pelatihan model CNN berbasis *transfer learning*, dan diakhiri dengan evaluasi

performa model menggunakan metrik klasifikasi. Alur ini dirancang untuk memastikan bahwa model yang dihasilkan memiliki kemampuan generalisasi yang baik dan dapat diterapkan pada kondisi nyata dapat dilihat pada Gambar 1.



Gambar 1. Rancangan Alur Penelitian

## 4. HASIL DAN PEMBAHASAN

### 4.1. Hasil Pengujian Model CNN

Pengujian dilakukan menggunakan tiga arsitektur *Convolutional Neural Network* berbasis *transfer learning*, yaitu InceptionV3, VGG19, dan ResNet50, dengan memanfaatkan data uji yang tidak terlibat dalam proses pelatihan. Evaluasi kinerja model dilakukan menggunakan pendekatan *confusion matrix* untuk memperoleh nilai akurasi, presisi, *recall*, dan *F1-score*.

### 4.2. Rumus Evaluasi Kinerja

Metrik evaluasi dihitung menggunakan persamaan berikut:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

dengan *TP* (True Positive), *TN* (True Negative), *FP* (False Positive), dan *FN* (False Negative).

#### 4.3. Hasil Confusion Matrix

Hasil pengujian masing-masing model ditunjukkan melalui *confusion matrix* yang menggambarkan kemampuan model dalam mengklasifikasikan telur retak dan tidak retak.

Tabel 2. Confusion Matrix Pengujian Model InceptionV3

| Kelas Aktual / Prediksi | Retak | Tidak Retak |
|-------------------------|-------|-------------|
| Retak                   | 33    | 17          |
| Tidak Retak             | 0     | 50          |

Dari tabel 2 kita bisa lihat bahwa hasil *confusion matrix* pengujian data uji model ini menampilkan pada kelas Retak, jumlah citra *True Positive* yang diperoleh sebanyak 33 citra sedangkan jumlah *True Negative* sebanyak 17 citra, dari total citra sebanyak 50 citra. Pada kelas Tidak Retak jumlah citra *True Positive* yang diperoleh sebanyak 50 citra dan jumlah *True Negative* sebanyak 0 citra dari total citra sebanyak 50 citra.

Tabel 3. Confusion Matrix Pengujian Model VGG19

| Kelas Aktual / Prediksi | Retak | Tidak Retak |
|-------------------------|-------|-------------|
| Retak                   | 18    | 32          |
| Tidak Retak             | 0     | 50          |

Dilihat dari tabel 3 hasil *confusion matrix* pengujian model ini menunjukan pada kelas Retak, jumlah citra pengujian model ini menunjukan pada kelas retak, jumlah citra *True Positive* yang diperoleh adalah sebanyak 18 citra sedangkan pada jumlah *True Negative* adalah sebanyak 32 citra dari total citra sebanyak 50 citra. Pada kelas Tidak Retak jumlah citra *True Positive* yang diperoleh sebanyak 50 citra dan jumlah citra *True Negative* sebanyak 0 citra dari total citra sebanyak 50 citra.

Tabel 4. Confusion Matrix Pengujian Model ResNet50

| Kelas Aktual / Prediksi | Retak | Tidak Retak |
|-------------------------|-------|-------------|
| Retak                   | 21    | 29          |
| Tidak Retak             | 2     | 48          |

Dilihat dari tabel 4 ini adalah Hasil *confusion matrix* pengujian model ini menunjukan pada kelas Retak, jumlah citra *True Positive* yang diperoleh adalah sebanyak 21 citra sedangkan pada jumlah *True Negative* yang diperoleh sebanyak 29 citra dari total citra sebanyak 50 citra. Pada kelas Tidak Retak jumlah citra *True Positive* yang diperoleh sebanyak

48 citra dan *True Negative* yang diperoleh sebanyak 2 citra dari total citra sebanyak 50 citra.

#### 4.4. Perbandingan Nilai Evaluasi Model

Berdasarkan *confusion matrix*, diperoleh nilai evaluasi kinerja masing-masing model seperti ditunjukkan pada Tabel 5.


Tabel 5. Perbandingan Nilai Akurasi, Precision, Recall, dan F1-Score

| Model       | Accuracy | Precision | Recall | F1-Score |
|-------------|----------|-----------|--------|----------|
| InceptionV3 | 83%      | 0,87      | 0,83   | 0,82     |
| VGG19       | 68%      | 0,80      | 0,68   | 0,64     |
| ResNet50    | 69%      | 0,76      | 0,69   | 0,67     |


Dari tabel tersebut dapat dilihat bahwa model InceptionV3 memperoleh nilai tertinggi pada seluruh metrik evaluasi, diikuti oleh VGG19 dan ResNet50.


#### 4.5. Gambar Hasil Pelatihan dan Evaluasi

Gambar 1. Grafik Akurasi dan Loss Proses Pelatihan Model InceptionV3.




Gambar 2. Grafik Akurasi dan Loss Proses Pelatihan Model InceptionV3





Gambar 3. Grafik Akurasi dan Loss Proses Pelatihan Model VGG19



Gambar 4. Grafik Akurasi dan Loss Proses Pelatihan Model ResNet50

Dari grafik-grafik tersebut dapat diamati bahwa model InceptionV3 menunjukkan konvergensi yang lebih stabil dengan selisih nilai *training* dan *validation loss* yang lebih kecil, menandakan kemampuan generalisasi yang lebih baik dibandingkan dua model lainnya

#### 4.6. Pembahasan

Hasil pengujian menunjukkan bahwa ketiga model CNN mampu melakukan klasifikasi keretakan telur ayam ras dengan tingkat akurasi yang baik. Namun, InceptionV3 memberikan performa terbaik secara konsisten pada seluruh metrik evaluasi. Keunggulan ini dapat dikaitkan dengan arsitektur *inception module* yang mampu mengekstraksi fitur pada berbagai skala secara simultan, sehingga lebih efektif dalam mengenali pola keretakan yang bervariasi pada permukaan telur. Model VGG19 menunjukkan performa yang stabil, tetapi memiliki kecenderungan *overfitting* akibat jumlah parameter

yang besar. Sementara itu, ResNet50 meskipun memiliki mekanisme *residual connection*, belum mampu mengungguli InceptionV3 dalam menangkap karakteristik retakan halus pada dataset yang digunakan.

Penerapan teknik *image augmentation* terbukti membantu meningkatkan kemampuan generalisasi model, terutama dalam menghadapi variasi orientasi, pencahayaan, dan kondisi permukaan telur yang tidak seragam. Berdasarkan hasil tersebut, sistem klasifikasi berbasis CNN dengan arsitektur InceptionV3 berpotensi diterapkan sebagai sistem inspeksi kualitas telur ayam ras secara otomatis. Pendekatan ini dapat membantu mengurangi kesalahan inspeksi manual serta meningkatkan efisiensi dan konsistensi dalam proses seleksi telur pada industri peternakan dan pangan.

#### 5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan sistem klasifikasi keretakan telur ayam ras berbasis *Convolutional Neural Network* (CNN) dengan pendekatan *transfer learning*. Tiga arsitektur CNN, yaitu InceptionV3, VGG19, dan ResNet50, telah diuji dan dibandingkan menggunakan metrik evaluasi berbasis *confusion matrix* yang meliputi akurasi, presisi, recall, dan F1-score. Hasil pengujian menunjukkan bahwa model InceptionV3 memberikan kinerja terbaik dibandingkan model lainnya dalam mendeteksi keretakan telur ayam ras, terutama pada kondisi permukaan telur yang bervariasi dan sebagian kotor. Temuan ini menunjukkan bahwa pendekatan CNN berbasis *transfer learning* efektif diterapkan untuk inspeksi kualitas telur secara otomatis. Untuk penelitian selanjutnya, disarankan menggunakan dataset dengan jumlah dan variasi yang lebih besar, menerapkan teknik optimasi hiperparameter, serta mengembangkan sistem dalam bentuk aplikasi *real-time* agar dapat digunakan secara langsung di lingkungan industri peternakan dan pangan.

#### DAFTAR PUSTAKA

- [1] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*. Pearson, 2018. [Online]. Available: <https://books.google.co.id/books?id=0F05vgAACAAJ>
- [2] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [3] I. Goodfellow, Y. Bengio, and A. Courville, "Regularization for deep learning," *Deep learning*, vol. 1, pp. 224–270, 2016.
- [4] L. Ali, F. Alnajjar, H. Al Jassmi, M. Gochoo, W. Khan, and M. A. Serhani, "Performance evaluation of deep CNN-based crack detection and localization techniques for concrete structures," *Sensors*, vol. 21, no. 5, pp. 1–22, Mar. 2021, doi: 10.3390/s21051688.

- [5] B. Botta, S. S. R. Gattam, and A. K. Datta, "Eggshell crack detection using deep convolutional neural networks," *J Food Eng*, vol. 315, Feb. 2022, doi: 10.1016/j.jfoodeng.2021.110798.
- [6] I. E. Hendarawan, Riza Ibnu Adam, and Chaerur Rozikin, "Klasifikasi Retak Ban Kendaraan Menggunakan Arsitektur ResNet50," *SATIN - Sains dan Teknologi Informasi*, vol. 9, no. 1, pp. 22–32, Jun. 2023, doi: 10.33372/stn.v9i1.902.
- [7] K. Fukushima, "Biological Cybernetics Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position," 1980.
- [8] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks." [Online]. Available: <http://code.google.com/p/cuda-convnet/>
- [9] M. Ali, M. Yaseen, S. Ali, and H. C. Kim, "Deep Learning-Based Approach for Microscopic Algae Classification with Grad-CAM Interpretability," *Electronics (Switzerland)*, vol. 14, no. 3, Feb. 2025, doi: 10.3390/electronics14030442.
- [10] B. J. F. Palandi A., *PENGOLAHAN CITRA DIGITAL MENGGUNAKAN VISUAL BASIC*, Pertama. Yogyakarta: Graha Ilmu, 2005.
- [11] A. Fanggidae, A. M. Dwitala, Y. T. Polly, and B. B. Koten, "Klasifikasi Citra Biji Arbi di Kabupaten Kupang menggunakan k-Nearest Neighbor berdasarkan fitur Warna dan Tekstur," *Telekontran : Jurnal Ilmiah Telekomunikasi, Kendali dan Elektronika Terapan*, vol. 12, no. 2, pp. 177–186, Oct. 2024, doi: 10.34010/telekontran.v12i2.14207.
- [12] F. Asriani, G. Pamudji, H. Susilawati, and F. T. Anggoro, "APLIKASI CONVOLUTIONAL NEURAL NETWORKS (CNN) UNTUK KLASIFIKASI RETAKAN BETON APPLICATION OF CONVOLUTIONAL NEURAL NETWORKS (CNN) FOR CLASSIFICATION CRACK OF CONCRETE." [Online]. Available: <http://dinarek.unsoed.ac.id>
- [13] F. Rochman and H. Junaedi, "Implementasi Transfer Learning untuk Identifikasi Ordo Tumbuhan melalui Daun," *Jurnal Syntax Admiration*, vol. 1, no. 6, pp. 672–679, 2020.
- [14] J. Yosinski, J. Clune, Y. Bengio, and H. Lipson, "How transferable are features in deep neural networks?," Nov. 2014, [Online]. Available: <http://arxiv.org/abs/1411.1792>
- [15] X. Xu *et al.*, "Crack Detection and Comparison Study Based on Faster R-CNN and Mask R-CNN," *Sensors*, vol. 22, no. 3, Feb. 2022, doi: 10.3390/s22031215.
- [16] R. Febrianti Malelak, A. Fanggidae, T. Widiastuti, and Y. T. Polly, "Informasi Kadar Natrium pada Label Produk Kemasan Menggunakan FPN, Faster R-CNN."
- [17] Y. T. Polly, A. Fanggidae, J. R. M. Ledoh, C. E. Amos Pah, B. S. Djahi, and K. E. R. Tupen, "A new approach for diabetes risk detection using quadratic interpolation flower pollination neural network," *Applied Computer Science*, vol. 21, no. 2, pp. 63–81, 2025, doi: 10.35784/acs\_7186.