



## Pemanfaatan Citra Digital Dan Algoritma Cnn Untuk Memprediksi Waktu Panen Kacang Tanah Yang Paling Tepat

Muh.Arfa Wahli Pratama<sup>1</sup>, Suryadi<sup>2</sup>, Asriani Ismail<sup>3\*</sup>

<sup>1,2</sup>Teknik Komputer, Fakultas Teknik, Universitas Muhammadiyah Kolaka utara, Indonesia

Manajemen Informatika, fakultas Ilmu Komputer, Universitas Handayani Makassar<sup>3</sup>

Email: muharfahwahlipratama@gmail.com<sup>1</sup>, suryadi@mukota.ac.id<sup>2</sup>, asrianiismail07@gmail.com<sup>3\*</sup>

\*Penulis Korespondensi

### Abstrak

Penentuan waktu panen yang tepat krusial untuk menjaga kualitas hasil kacang tanah. Namun, petani sering menghadapi kesulitan dalam menentukan status panen secara cepat dan akurat. Penelitian ini bertujuan mengembangkan aplikasi deteksi waktu panen optimal kacang tanah berbasis Android menggunakan citra digital untuk mendukung pengambilan keputusan petani. Metode yang diimplementasikan adalah *Convolutional Neural Network* (CNN) dengan arsitektur ResNet50. *Dataset* penelitian terdiri dari 510 citra digital yang diklasifikasikan ke dalam tiga kategori (Belum Siap Panen, Siap Panen, dan Terlambat Panen), dibagi menjadi 70% data pelatihan, 15% data validasi, dan 15% data pengujian. Hasil pengujian menunjukkan *model* ResNet50 mampu mencapai akurasi keseluruhan sebesar 90%. Kinerja *model* didukung oleh nilai rata-rata *precision* 0.91, *recall* 0.89, dan *F1-Score* 0.89. Selain itu, nilai *Area Under Curve* (AUC) untuk setiap kelas sangat tinggi, berada pada rentang 0.98 hingga 1.00. Meskipun hasil *5-Fold Cross Validation* menghasilkan rata-rata akurasi yang lebih rendah (43%), hasil pengujian utama membuktikan bahwa arsitektur CNN-ResNet50 efektif dan berpotensi sebagai alat bantu akurat bagi petani dalam menentukan waktu panen kacang tanah yang optimal.

**Kata kunci:** Kacang Tanah, Deteksi Waktu Panen, CNN, ResNet50, Android.

### Abstract

*Determining the right harvest time is crucial for maintaining the quality of peanut yields. However, farmers often face difficulties in determining harvest status quickly and accurately. This study aims to develop an Android-based application for detecting optimal peanut harvest time using digital images to support farmer decision-making. The implemented method is a Convolutional Neural Network (CNN) with the ResNet50 architecture. The research dataset consists of 510 digital images classified into three categories (Not Ready for Harvest, Ready for Harvest, and Late Harvest), divided into 70% training data, 15% validation data, and 15% testing data. The test results show that the ResNet50 model is able to achieve an overall accuracy of 90%. Model performance is supported by an average precision value of 0.91, recall of 0.89, and F1-Score of 0.89. In addition, the Area Under Curve (AUC) value for each class is very high, ranging from 0.98 to 1.00. Although the 5-Fold Cross Validation results produced a lower average accuracy (43%), the main test results proved that the CNN-ResNet50 architecture is effective and has the potential to be an accurate tool for farmers in determining the optimal peanut harvest time.*

**Keywords:** Peanut, Harvest Time Detection, CNN, ResNet50, Android.

## 1. PENDAHULUAN

Kacang tanah (*Arachis hypogaea* L.) merupakan komoditas multi fungsi yang dapat disebut sebagai bio industri. Selain dikonsumsi langsung dalam bentuk biji segar, kacang tanah juga digunakan sebagai bahan baku dalam industri makanan olahan, minyak nabati, dan batangnya sebagai pakan ternak [1]. Seiring dengan berkembangnya industri pangan dan pakan ternak berbahan baku kacang tanah, permintaan terhadap komoditas ini semakin meningkat. Namun, produksi kacang tanah di Indonesia saat ini masih tergolong rendah dan belum dapat memenuhi permintaan yang terus berkembang.

Dengan kemajuan teknologi, khususnya dalam pengolahan citra digital dan kecerdasan buatan, Implementasi teknologi *deep learning* dalam pertanian telah menunjukkan hasil yang menjanjikan[2]. CNN telah terbukti menjadi alat yang efektif dalam menganalisis dan mengenali pola visual secara otomatis. Sebagai salah satu arsitektur *deep learning*, CNN memiliki kemampuan untuk mengekstraksi fitur penting dari citra digital tanpa memerlukan intervensi manual.

Penelitian ini mengembangkan sistem deteksi waktu panen kacang tanah menggunakan arsitektur CNN ResNet50, yang dipilih karena kemampuannya mengekstrak fitur visual kompleks secara mendalam tanpa degradasi performa. Sistem ini bekerja dengan menganalisis citra digital daun—sebagai indikator visual utama—untuk memprediksi umur tanaman dan menentukan kesiapan panen. Model ResNet50 secara spesifik dilatih untuk mengenali perubahan warna dan tekstur daun yang terkait dengan pematangan alami, serta mampu membedakannya dari daun yang menguning akibat penyakit, di mana *dataset* yang digunakan hanya berfokus pada tanaman sehat untuk menjamin akurasi deteksi kematangan.

Penelitian ini membedakan diri dari metode penentuan panen sebelumnya, seperti metode Akumulasi Satuan Panas (*Heat Unit*) yang memiliki ketergantungan tinggi pada kondisi lingkungan yang sulit dikontrol. Meskipun *Convolutional Neural Network* (CNN) telah diterapkan untuk estimasi usia manusia, aplikasinya pada objek non-manusia di bidang agrikultur masih terbatas. Oleh karena itu, penelitian ini mengusulkan implementasi arsitektur CNN-ResNet50 untuk menganalisis citra digital daun kacang tanah (224x224 piksel) sebagai indikator visual kematangan tanaman. Penelitian ini merupakan implementasi pertama CNN-ResNet50 pada platform Android untuk kasus spesifik deteksi waktu panen kacang tanah. Sistem ini dirancang untuk mengatasi kelemahan metode manual dan memberikan rekomendasi panen yang lebih akurat dan otomatis kepada petani, guna meningkatkan hasil panen serta meminimalisir kerugian akibat waktu panen yang tidak tepat.

## **2. KAJIAN TEORITIS**

Kacang tanah (*Arachis hypogaea L.*) merupakan komoditas multifungsi yang penting, baik sebagai bahan pangan, industri olahan, minyak nabati, maupun pakan ternak[3]. Permasalahan krusial dalam budidayanya adalah ketidaktepatan penentuan waktu panen . Jika panen terlalu cepat (dini), mutu dan hasil akan menurun karena biji

belum terisi penuh dan kadar lemaknya rendah[4]. Sebaliknya, keterlambatan panen dapat mengurangi jumlah polong yang terambil dan meningkatkan risiko serangan jamur yang menurunkan kualitas biji .

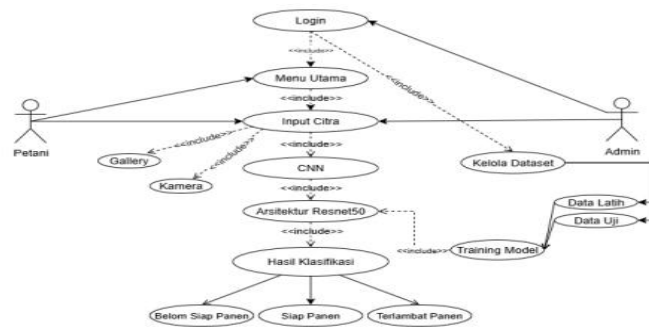
Penelitian ini memanfaatkan citra digital sebagai data *input* utama, yang merupakan implementasi dari kemajuan teknologi pengolahan citra dan kecerdasan buatan[5]. Citra daun tanaman diolah dalam ukuran standar  $224 \times 224$  piksel untuk digunakan sebagai *input* dalam melatih *model* prediksi . Daun dipilih karena berfungsi sebagai indikator visual utama; perubahan warna (misalnya, dari hijau menjadi kuning atau coklat) dan tekstur daun dapat mencerminkan tahap perkembangan dan kematangan tanaman .

### **3. METODE PENELITIAN**

Metode penelitian ini berfokus pada pengembangan sistem klasifikasi citra menggunakan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur ResNet50 untuk diimplementasikan pada aplikasi Android. Penelitian ini memanfaatkan *dataset* sebanyak 510 citra digital daun kacang tanah yang telah melalui pra-pemrosesan ke ukuran  $224 \times 224$  piksel. Citra tersebut diklasifikasikan ke dalam tiga kategori status panen, yaitu Belum Siap Panen, Siap Panen, dan Terlambat Panen. *Dataset* kemudian dibagi menjadi 70% data pelatihan (357 citra), 15% data validasi (76 citra), dan 15% data pengujian (76 citra). Untuk mengevaluasi kinerja *model*, penelitian ini menggunakan beberapa metode pengujian, meliputi analisis *Confusion Matrix* , perhitungan nilai Akurasi, *Precision*, *Recall*, dan *F1-Score* , serta pengujian *Area Under Curve* (AUC) pada kurva ROC dan *5-Fold Cross Validation*. Selain itu, pengujian fungsionalitas aplikasi dilakukan menggunakan metode *Black Box Testing*.

#### **a. Desain Penelitian**

Penelitian ini dirancang dalam bentuk prototipe aplikasi berbasis Android. Komponen utama yang digunakan adalah perangkat lunak (*software*) yang mencakup *model deep learning Convolutional Neural Network* (CNN) dengan arsitektur ResNet50. Perancangan sistem perangkat lunak ini dimodelkan menggunakan UML (*Unified Modelling Language*), yang meliputi *Use Case Diagram*, *Activity Diagram*, *Sequence Diagram*, dan *Class Diagram*, untuk menggambarkan alur kerja dan fungsionalitas aplikasi.



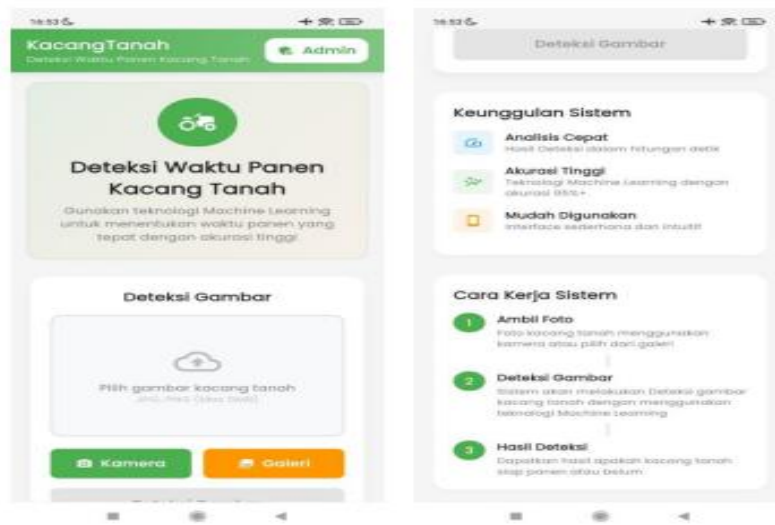
Gambar 1. Use Case Diagram

### b. Populasi dan Sampel Penelitian

Populasi penelitian ini mencakup keseluruhan citra digital daun tanaman kacang tanah yang merepresentasikan berbagai tahap kematangan. Sampel yang digunakan dalam penelitian ini berjumlah 510 citra digital yang telah dikumpulkan dan diolah. Sampel tersebut kemudian diklasifikasikan secara *purposive* ke dalam tiga kategori[6] untuk mewakili kondisi panen yang nyata, yaitu "Belum Siap Panen", "Siap Panen", dan "Terlambat Panen". *Dataset* ini selanjutnya dibagi menjadi 70% data pelatihan, 15% data validasi, dan 15% data pengujian. Data pengujian (sampel uji) digunakan untuk menilai performa *model* dalam mengenali setiap kelas, dengan parameter yang diamati untuk mengukur keandalan *model* meliputi Akurasi, *Precision*, *Recall*, *F1-Score*, serta analisis Kurva ROC (AUC).

### c. Teknik dan Instrumen Pengumpulan Data

Teknik pengumpulan data dalam penelitian ini dilakukan melalui akuisisi citra digital (pengambilan gambar) secara langsung pada objek penelitian, yaitu daun tanaman kacang tanah. Instrumen utama yang digunakan adalah kamera (seperti kamera smartphone) untuk menangkap kondisi visual daun pada berbagai tahap kematangan, menghasilkan total 510 citra. Data mentah ini kemudian diolah menggunakan instrumen perangkat lunak (*software*) untuk pelabelan (*labeling*), di mana setiap citra diklasifikasikan secara manual ke dalam tiga kategori (Belum Siap Panen, Siap Panen, Terlambat Panen)[7]. Selain itu, pengujian sistem menggunakan teknik *Black Box Testing* untuk mengevaluasi fungsionalitas aplikasi Android, serta pengujian kinerja *model* (evaluasi) untuk mengukur performa *model* CNN menggunakan metrik seperti *Confusion Matrix*, Akurasi, *Precision*, *Recall*, dan *F1-Score*[8].



Gambar 2. Tampilan Sistem

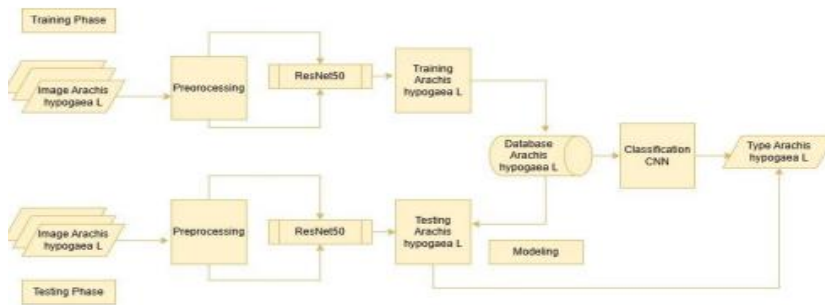
#### d. Analisis Data

Analisis data dalam penelitian ini dilakukan dengan menggunakan pendekatan kuantitatif deskriptif untuk menggambarkan performa *model Convolutional Neural Network* (CNN) secara objektif. Data yang diperoleh dari hasil uji coba (pengujian) diolah dengan menghitung nilai Akurasi (keberhasilan klasifikasi), *Precision*, *Recall*, dan *F1-Score* sebagai indikator konsistensi dan keandalan *model*. Selanjutnya, hasil pengukuran dari setiap kelas kategori (baik "Belum Siap Panen", "Siap Panen", maupun "Terlambat Panen") dianalisis melalui *Confusion Matrix* untuk menilai efektivitas arsitektur ResNet50 yang diterapkan dalam menghadapi data yang berbeda. Analisis ini, yang juga didukung oleh pengujian Kurva ROC (AUC) dan *5-Fold Cross Validation*, menunjukkan keunggulan maupun keterbatasan *model* serta memberikan gambaran menyeluruh mengenai kemampuan sistem dalam mendeteksi status panen secara akurat[9].

#### e. Model Penelitian

*Model* penelitian ini dibangun dengan menempatkan citra digital daun kacang tanah sebagai variabel bebas (*input*), yang merepresentasikan kondisi visual (seperti warna dan tekstur) yang berbeda. Sedangkan variabel terikatnya (*output*) [10] adalah hasil prediksi status panen yang diukur melalui indikator Akurasi, *Precision*, *Recall*, dan *F1-Score* dari *model* klasifikasi. Hubungan antar variabel diasumsikan bersifat prediktif, di mana perubahan fitur visual pada citra daun akan memengaruhi hasil klasifikasi (Belum

Siap, Siap, atau Terlambat Panen) yang ditentukan oleh *model* CNN. Dengan demikian, *model* penelitian ini memberikan kerangka analisis untuk menilai seberapa besar efektivitas arsitektur ResNet50 dalam mendeteksi status kematangan tanaman berdasarkan data visual yang diuji.



Gambar 3. Alur Kerja Sistem


## 4. HASIL DAN PEMBAHASAN

### a. Hasil Pengujian

Pengujian *model* CNN (ResNet50) dilakukan pada *dataset* uji yang telah disiapkan dengan tiga kategori (kelas), yaitu "Belum Siap Panen", "Siap Panen", dan "Terlambat Panen". Setiap kategori dalam data uji (total 76 citra) dievaluasi untuk memperoleh nilai performa. Parameter yang diamati meliputi Akurasi, *Precision*, *Recall*, *F1-Score*, serta tingkat keberhasilan *model* dalam mengklasifikasikan setiap gambar ke kategori yang tepat, yang dianalisis menggunakan *Confusion Matrix*.

Tabel 1. Nilai Pixel RGB 4x4


<b>R: 115</b> <b>G: 122</b> <b>B: 81</b>	<b>R: 105</b> <b>G: 134</b> <b>B: 64</b>	<b>R: 162</b> <b>G: 180</b> <b>B: 52</b>	<b>R: 194</b> <b>G: 205</b> <b>B: 105</b>
<b>R: 72</b> <b>G: 98</b> <b>B: 54</b>	R: 96 G: 124 B: 66	R: 112 G: 153 B: 40	<b>R: 166</b> <b>G: 152</b> <b>B: 86</b>
<b>R: 76</b> <b>G: 114</b> <b>B: 55</b>	R: 93 G: 138 B: 84	R: 93 G: 134 B: 68	<b>R: 119</b> <b>G: 152</b> <b>B: 80</b>
<b>R: 93</b> <b>G: 131</b> <b>B: 50</b>	<b>R: 77</b> <b>G: 107</b> <b>B: 38</b>	<b>R: 81</b> <b>G: 107</b> <b>B: 44</b>	<b>R: 119</b> <b>G: 91</b> <b>B: 69</b>



Gambar 4. Grafik Hasil Uji *Training and Validation Accuracy Model*

Gambar di atas menunjukkan grafik hasil pelatihan *model Convolutional Neural Network* (CNN) dengan arsitektur ResNet50, yang menampilkan hubungan antara akurasi dan loss pada data *training* serta *validation* selama 20 *epoch*. Grafik sebelah kiri memperlihatkan tren peningkatan akurasi baik pada data pelatihan maupun validasi. Akurasi *training* meningkat secara bertahap hingga mencapai nilai mendekati 0.88, sedangkan akurasi validasi cenderung berfluktuasi namun stabil di kisaran 0.80–0.85, yang menunjukkan bahwa *model* mampu melakukan generalisasi dengan baik. Pada grafik sebelah kanan terlihat penurunan nilai loss pada data *training* dan *validation* seiring bertambahnya *epoch*, meskipun terdapat sedikit fluktuasi di akhir pelatihan. Hal ini menandakan bahwa *model* mengalami proses pembelajaran yang efektif tanpa indikasi overfitting yang signifikan. Secara keseluruhan, hasil ini menunjukkan bahwa arsitektur ResNet50 dapat mempelajari fitur citra daun kacang tanah secara optimal untuk mendeteksi status panen dengan tingkat akurasi yang tinggi dan stabilitas *model* yang baik.

*Confusion matrix* merupakan metode evaluasi yang digunakan untuk membandingkan hasil prediksi dari *model* klasifikasi dengan label sebenarnya. Dalam penelitian ini, dilakukan pengujian deteksi waktu panen optimal tanaman kacang tanah menggunakan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur ResNet50. *Dataset* yang digunakan terdiri dari 510 citra digital, yang dibagi menjadi 70% data latih (357 citra), 15% data validasi (76 citra), dan 15% data uji (76 citra).



Gambar 5. Pengujian Confusion Matrix


Berikut penjelasan *Confusion Matrix* Hasil Deteksi Waktu Panen Kacang Tanah : a.

Kelas Belum Siap Panen : dari 26 citra uji, sebanyak 24 citra berhasil diklasifikasikan dengan benar sebagai Belum Siap Panen. Namun, terdapat 1 citra salah dikenali sebagai Siap Panen dan 1 citra lainnya salah dikenali sebagai Terlambat Panen. b. Kelas Siap Panen : dari 25 citra uji, seluruhnya berhasil dikenali dengan benar sebagai Siap Panen tanpa ada kesalahan klasifikasi. c.

Kelas Terlambat Panen : dari 25 citra uji, sebanyak 24 citra berhasil diklasifikasikan dengan benar sebagai Terlambat Panen, sedangkan 1 citra salah dikenali sebagai Belum Siap Panen. Berikut proses perhitungannya :

Tabel 2 Akurasi Tiap Kelas

	Data Benar/Total Data	Accuracy
<b>Belum Siap Panen</b>	24 /26	<b>92%</b>
<b>Siap_Panen</b>	22/25	<b>88%</b>
<b>Terlambat Panen</b>	22/25	<b>88%</b>



Gambar 6 Akurasi Setiap Kelas

Pada gambar di atas ditampilkan perbandingan tingkat akurasi *model* untuk setiap



kelas. Dapat dilihat bahwa kelas *Belum Siap Panen* memiliki akurasi tertinggi yaitu 92%, sedangkan kelas *Siap Panen* dan *Terlambat Panen* memiliki akurasi yang sama yaitu 88%. Hal ini menunjukkan bahwa *model* masih memiliki sedikit kesulitan dalam membedakan daun pada fase siap panen dan terlambat panen, yang kemungkinan disebabkan oleh kemiripan visual antar keduanya.

Tabel 3 *Classification Report*

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<b>Support</b>
<b>Belum Siap Panen</b>	0.80	0.92	0.85	<b>26</b>
<b>Siap Panen</b>	1.00	0.88	0.93	<b>25</b>
<b>Terlambat Panen</b>	0.92	0.88	0.90	<b>25</b>
<b>Macro Avg</b>	0.91	0.89	0.89	<b>76</b>
<b>Accuracy</b>	<b>0.90</b>			<b>76</b>

perbaikan pada variasi *dataset* terutama pada kelas *Belum Siap Panen* untuk meningkatkan

## 5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan aplikasi Android yang terintegrasi dengan *model* CNN ResNet50 melalui REST API Flask untuk mendeteksi status panen kacang tanah secara *real-time* berdasarkan citra daun. *Model* ResNet50 menunjukkan performa yang baik pada 76 data uji dengan akurasi 90%, *precision* 0.91, *recall* 0.89, dan *F1-Score* 0.89. Meskipun hasil *5-Fold Cross Validation* menunjukkan rata-rata akurasi yang lebih rendah (43%), yang mengindikasikan sensitivitas terhadap distribusi data, ResNet50 tetap dipilih karena hasil kompetitif (akurasi 89.47%) dibandingkan arsitektur lain serta stabilitas dan kompatibilitasnya yang tinggi untuk implementasi *real-time*. Penelitian ini memiliki kebaruan sebagai implementasi pertama ResNet50 untuk deteksi panen kacang tanah pada sistem Android, menawarkan solusi praktis bagi petani melalui integrasi *deep learning*, REST API, dan aplikasi *mobile*, robotika, elektronika, serta pemrograman mikrokontroler.

Untuk pengembangan penelitian ke depan, disarankan peningkatan kualitas dan kuantitas *dataset* dengan variasi kondisi lapangan yang lebih beragam, seperti pencahayaan dan latar belakang, agar *model* lebih robust. Selain itu, perlu dieksplorasi metode deteksi otomatis seperti YOLOv8 untuk mengenali daun secara langsung tanpa pemotongan citra manual. Terakhir, implementasi teknologi *Edge AI* diusulkan agar

model CNN dapat dijalankan langsung pada perangkat Android tanpa memerlukan koneksi internet, sehingga aplikasi lebih efisien, responsif, dan dapat digunakan di area dengan keterbatasan jaringan

#### .DAFTAR REFERENSI

- [1] Latif, A., Widodo, H. A., Rahim, R., & Kunal, K. (2020). Implementation of *line follower* robot based microcontroller atmega32a. *Journal of Robotics and Control (JRC)*, 1(3), 70–74. <https://doi.org/10.18196/jrc.1316>. [1] G. Fernandes *et al.*, “No 主観的健康感を中心とした在宅高齢者における 健康関連指標に関する共分散構造分析Title,” *New Phytol.*, vol. 51, no. 1, p. 2022, 2022, [Online]. Available: [https://doi.org/10.20935/AL189%0Ahttps://www.researchgate.net/publication/269107473\\_What\\_is\\_governance/link/548173090cf22525dcb61443/download%0Ahttp://www.econ.upf.edu/~reynal/Civilwars\\_12December2010.pdf%0Ahttps://think-asia.org/handle/11540/8282%0Ahttps://](https://doi.org/10.20935/AL189%0Ahttps://www.researchgate.net/publication/269107473_What_is_governance/link/548173090cf22525dcb61443/download%0Ahttp://www.econ.upf.edu/~reynal/Civilwars_12December2010.pdf%0Ahttps://think-asia.org/handle/11540/8282%0Ahttps://)
- [2] R. B. A. A. M. F. F. B. T. A. N. K. J. T. J. C. L. Khaidir, “(88-99)+-+Klasifikasi+Tingkat+Kesegaran+Sayur+Bayam...,” vol. 2022, pp. 88–99, 2023.
- [3] Alfito Herdiansyah, Arief Hermawan, and Sutarman, “Implementasi Algoritma *Convolutional Neural Network* Untuk Identifikasi Kode Seri Keramik Merk Arwana,” *J. Fasilkom*, vol. 14, no. 3, pp. 581–589, 2024, doi: 10.37859/jf.v14i3.8060.
- [4] S. Ainah, Y. N. C. Khotimah, A. Maharani, V. H. Pranatawijaya, and R. Priskila, “Implementasi Sistem Pakar Forward Chaining pada Deteksi Penyakit Tanaman Selada,” *J. Minfo Polgan*, vol. 13, no. 1, pp. 241–253, 2024, doi: 10.33395/jmp.v13i1.13613.
- [5] M. Rahman and A. Pambudi, “Identifikasi Citra Daun Selada Dalam Menentukan Kualitas Tanaman Menggunakan Algoritma *Convolutional Neural Network* (Cnn),” *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 3, pp. 2830–7062, 2023, [Online]. Available: <http://dx.doi.org/10.23960/jitet.v11i3.s1.3438>
- [6] Ш. Ревитшвили, “No 主観的健康感を中心とした在宅高齢者における 健康関連指標に関する共分散構造分析Title,” *Брадиаритмии И Нарушения*

- Проводимости*, 2025, [Online]. Available:  
[http://scioteca.caf.com/bitstream/handle/123456789/1091/RED2017-Eng-8ene.pdf?sequence=12&isAllowed=y%0Ahttp://dx.doi.org/10.1016/j.regsciurbeco.2008.06.005%0Ahttps://www.researchgate.net/publication/305320484\\_SYSTEM\\_PEMBETUNGAN\\_TERPUSAT\\_STRATEGI\\_MELESTARI](http://scioteca.caf.com/bitstream/handle/123456789/1091/RED2017-Eng-8ene.pdf?sequence=12&isAllowed=y%0Ahttp://dx.doi.org/10.1016/j.regsciurbeco.2008.06.005%0Ahttps://www.researchgate.net/publication/305320484_SYSTEM_PEMBETUNGAN_TERPUSAT_STRATEGI_MELESTARI)
- [7] D. S. Candra, “Implementasi *Convolutional Neural Network* (CNN) Untuk Klasifikasi Citra Bunga,” vol. 16, no. 1, pp. 2580–2582, 2020.
- [8] P. Doll, R. Girshick, and F. Ai, “Mask R-CNN ar”.
- [9] N. Umar, F. Haikal, and M. Razak, “Citra Digital Untuk Klasifikasi Kualitas Udang Windu Menggunakan Algoritma GLCM dan K-Nearest Neighbor,” *J. Inform.*, vol. 9, no. 2, pp. 93–102, 2022, doi: 10.31294/inf.v9i2.13686.
- [10] R. G. Guntara, “Ekstraksi Fitur Warna Citra Daun Untuk Klasifikasi Skala Klorofil dan Rekomendasi Pemupukan,” *J. Minfo Polgan*, vol. 11, no. 1, pp. 15–22, 2022, doi: 10.33395/jmp.v11i1.11644.