

## EXPLAINABLE DEEP LEARNING FOR BEEF FRESHNESS CLASSIFICATION USING GRAD-CAM VISUALIZATION

Ade Bastian<sup>1</sup>, Ardi Mardiana<sup>2</sup>, Billy Adrian Fernanda<sup>3</sup>, Harun Sujadi<sup>4</sup>, Abrar Wahid<sup>5</sup>, Riri Nurazizah<sup>6</sup>, Wildan Zhilal Manafi<sup>7</sup>

<sup>1,2,3,4,5,6,7</sup>Universitas Majalengka, Majalengka, Indonesia

Responden: 211410135@unma.ac.id

### ABSTRAK

Kesegaran daging sapi merupakan faktor kritis bagi keamanan pangan di Indonesia, mengingat tingginya tingkat konsumsi dan impor komoditas ini. Metode penilaian kesegaran tradisional seringkali lambat, destruktif (merusak), atau bias secara subjektif. Penelitian ini bertujuan untuk mengembangkan model Deep Learning yang tidak hanya akurat dalam mengklasifikasikan kesegaran daging sapi (Segar, Setengah Segar, Busuk) tetapi juga dapat dijelaskan (explainable) dalam proses pengambilan keputusannya. Kami menerapkan Transfer Learning menggunakan arsitektur Convolutional Neural Network (CNN) yang ringan, yaitu MobileNetV2, pada dataset yang terdiri dari 2.266 citra daging yang telah diaugmentasi. Untuk mengatasi sifat "black-box" dari CNN, Gradient-weighted Class Activation Mapping (Grad-CAM) diimplementasikan untuk memvisualisasikan area fokus model. Hasil eksperimen menunjukkan bahwa model kami yang telah di-fine-tune mencapai akurasi validasi yang tinggi (96,01%), dengan presisi sempurna (100%) untuk kelas 'Busuk' (Spoiled), memastikan tidak ada daging busuk yang salah diklasifikasikan sebagai daging segar. Analisis Grad-CAM lebih lanjut memvalidasi bahwa model mendasarkan keputusannya pada fitur visual yang relevan secara biologis, seperti pola perubahan warna dan tekstur permukaan, bukan pada noise latar belakang. Temuan ini mengonfirmasi potensi integrasi CNN ringan dengan XAI untuk sistem kontrol kualitas yang andal, non-destruktif, dan transparan dalam industri pangan.

**Kata Kunci:** *Beef Freshness, Deep Learning, Grad-CAM, MobileNetV2, XAI*

---

### Riwayat Artikel :

Tanggal diterima : 11-11-2025

Tanggal revisi : 12-12-2025

Tanggal terbit : 15-12-2025

### DOI :

<https://doi.org/10.31949/infotech.v11i2.16897>

**INFOTECH journal** by Informatika UNMA is licensed under CC BY-SA 4.0

Copyright © 2025 By Author



## 1. PENDAHULUAN

Keamanan pangan merupakan pilar fundamental dalam pembangunan nasional dan ketahanan rantai pasok global, terutama dalam menghadapi tantangan distribusi yang kompleks. Penerapan kecerdasan buatan (Artificial Intelligence/AI) dalam industri pangan kini telah berkembang pesat, menawarkan solusi inovatif mulai dari pemantauan kualitas secara real-time hingga prediksi keamanan produk di sepanjang rantai distribusi. (Jayan et al., 2025) Di Indonesia, daging sapi sebagai sumber protein utama memiliki tingkat konsumsi yang terus meningkat. Namun, ketergantungan pada impor yang tinggi menuntut sistem pengawasan mutu yang ketat untuk mencegah peredaran daging yang tidak layak konsumsi akibat pembusukan mikroba atau oksidasi. (Regita, Z., & Daspar, D, 2025)

Tantangan utama dalam pengawasan mutu saat ini adalah keterbatasan metode konvensional. Pengujian mikrobiologis laboratorium memberikan hasil akurat namun bersifat destruktif dan memakan waktu, sedangkan penilaian sensoris manusia seringkali subjektif dan tidak konsisten. Oleh karena itu, pendekatan non-destruktif yang mengintegrasikan sensor optik dan computer vision semakin menjadi pilihan utama karena mampu memberikan penilaian kualitas yang cepat tanpa merusak sampel fisik. (Lee & Ma, 2025)

Dalam ranah computer vision, algoritma Deep Learning (DL) telah menunjukkan kinerja superior dibandingkan metode tradisional (Hidayatulloh et al., 2023) Meskipun arsitektur kompleks seperti ResNet mampu mencapai akurasi tinggi, tren industri saat ini, khususnya untuk implementasi pada perangkat mobile dan edge computing, mengarah pada penggunaan model yang lebih ringan (lightweight) dan efisien. (Gilal et al., 2024) Studi terbaru oleh Muttaqin & Arifudin pada buah-buahan (Muttaqin & Arifudin, 2024) dan Kılıçarslan et al. (2024) menunjukkan bahwa arsitektur MobileNetV2 mampu memberikan keseimbangan optimal antara akurasi tinggi dan efisiensi komputasi, menjadikannya kandidat ideal untuk sistem deteksi portabel.

Namun, penerapan DL di sektor kritis seperti keamanan pangan menghadapi tantangan besar terkait sifat "black-box" dari model tersebut, di mana logika pengambilan keputusan sulit dipahami oleh manusia. (Zullich et al., n.d.) Kurangnya transparansi ini dapat menghambat adopsi teknologi oleh pemangku kepentingan industri yang membutuhkan jaminan akuntabilitas. (Gbashi & Njobeh, 2024) Oleh karena itu, integrasi Explainable AI (XAI) menjadi krusial untuk meningkatkan kepercayaan pengguna dan ketahanan sistem keputusan. (Jauhar et al., 2024)

Berbagai teknik XAI telah dieksplorasi dalam domain pangan. Przybył menggunakan metode LIME untuk menginterpretasikan fitur tekstur pada bubuk buah, (Przybył, 2024) sementara Lima

mendemonstrasikan bahwa Gradient-weighted Class Activation Mapping (Grad-CAM) efektif dalam memvisualisasikan fitur morfologis krusial pada klasifikasi spesies ikan. (Lima, S. A., 2024) Mengadopsi keberhasilan tersebut ke dalam domain daging sapi, penelitian ini bertujuan mengembangkan model deteksi kesegaran daging sapi yang tidak hanya akurat tetapi juga transparan. Kami mengusulkan penggunaan arsitektur CNN ringan (MobileNetV2) yang diintegrasikan dengan Grad-CAM. Kontribusi utama penelitian ini adalah menyediakan evaluasi komprehensif yang memvalidasi bahwa model mengambil keputusan berdasarkan fitur biologis pembusukan daging yang relevan secara visual, bukan berdasarkan noise latar belakang, sehingga menjamin reliabilitas sistem untuk implementasi nyata.

Penelitian ini bertujuan untuk membangun model deteksi kesegaran daging sapi yang tidak hanya memiliki akurasi tinggi tetapi juga transparan. Kami mengusulkan penggunaan arsitektur CNN ringan (MobileNetV2) yang diintegrasikan dengan Grad-CAM. Kontribusi utama penelitian ini adalah menyediakan evaluasi komprehensif yang memvalidasi kinerja model tidak hanya secara statistik, tetapi juga secara visual, memastikan bahwa model mampu mengenali fitur biologis pembusukan daging yang sebenarnya.


## 2. METODE

### 2.1. Akuisisi dan Preparasi Dataset

Data yang digunakan dalam penelitian ini meliputi citra daging sapi dalam tiga kategori kualitas: segar (fresh), setengah segar (half-fresh), dan busuk (spoiled). Total dataset terdiri dari 2.266 citra yang dikumpulkan dalam berbagai kondisi pencahayaan untuk mensimulasikan lingkungan nyata, pendekatan yang disarankan dalam survei dataset pangan oleh Gilal et al. untuk memastikan ketahanan model terhadap variabilitas visual. (Gilal et al., 2024) Secara biologis, proses pembusukan daging ditandai dengan perubahan warna signifikan dari merah cerah (akibat oxymyoglobin) menjadi kecoklatan atau kehijauan (metmyoglobin dan sulfmyoglobin), serta perubahan tekstur permukaan yang divalidasi oleh studi proteomik Zhao et al. (Zhao et al., 2022) Dataset ini dibagi dengan rasio 80:20 untuk data latih dan data validasi guna memastikan evaluasi yang objektif.

### 2.2. Preprocessing dan Augmentasi Data

Untuk meningkatkan generalisasi model dan mencegah overfitting akibat keterbatasan jumlah data latih, teknik augmentasi data diterapkan. Sebagaimana diterapkan oleh Muttaqin dan Arifudin dalam deteksi kesegaran buah berbasis Android, teknik augmentasi yang meliputi rotasi, pergeseran (shifting), pembalikan (flipping), dan penyesuaian kecerahan (brightness) terbukti efektif memperkaya variasi fitur visual tanpa mengubah karakteristik intrinsik objek. (Muttaqin & Arifudin, 2024) Gambar 1 menunjukkan contoh hasil augmentasi yang diterapkan pada citra daging sapi.



Gambar 1. Contoh data hasil augmentasi

2.3. Arsitektur CNN Ringan

Penelitian ini berfokus pada arsitektur state-of-the-art yang dirancang untuk efisiensi komputasi, yaitu MobileNetV2. Arsitektur ini menggunakan depthwise separable convolutions dan inverted residual with linear bottleneck, sebuah inovasi struktural yang diperkenalkan oleh Sandler et al. (Sandler et al., n.d.) untuk mengurangi beban komputasi secara drastis. Pemilihan MobileNetV2 didasarkan pada studi komparatif oleh Kılıçarslan et al. yang menunjukkan bahwa model ini memberikan keseimbangan terbaik antara akurasi dan kecepatan dibandingkan VGG16 atau Xception dalam klasifikasi kesegaran produk hewani. (Kılıçarslan et al., 2024) Model ini digunakan sebagai feature extractor dengan bobot awal dari ImageNet (Transfer Learning), metode yang terbukti mempercepat konvergensi pada dataset pangan yang spesifik (Salma et al., 2023) Bagian classifier dimodifikasi dengan menambahkan lapisan Global Average Pooling, Dropout (rate 0.5) untuk regularisasi, dan Dense layer dengan aktivasi Softmax untuk 3 kelas output.

2.4. Implementasi Explainable AI (Grad-CAM)

Untuk mengatasi masalah "black-box" pada jaringan saraf tiruan dan memberikan transparansi keputusan, kami mengimplementasikan Gradient-weighted Class Activation Mapping (Grad-CAM). Teknik ini, yang dikembangkan oleh Cogswell et al. [9], menghitung gradien dari skor kelas target terhadap peta fitur pada lapisan konvolusi terakhir untuk memvisualisasikan area penting. (Cogswell et al., n.d.) Pendekatan ini sejalan dengan rekomendasi Arrighi et al. [2025] dan Mostafa et al. [2023] yang menekankan pentingnya visualisasi peta panas (heatmap) untuk memvalidasi bahwa model mempelajari fitur biologis yang relevan, bukan sekadar menghafal pola latar belakang. (Mostafa et al., 2023) Peta panas Grad-CAM dihasilkan melalui kombinasi linier berbobot dari peta fitur, diikuti oleh fungsi aktivasi ReLU:

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^f}{\partial A_{ij}^k} \quad (1)$$

Peta panas (heatmap) Grad-CAM kemudian dihasilkan melalui kombinasi linier berbobot dari peta fitur tersebut, diikuti oleh fungsi aktivasi ReLU untuk hanya mengambil fitur yang berkontribusi positif terhadap kelas target:

$$L_{Grad-CAM}^c = \text{ReLU}(\sum_k \alpha_k^c A^k) \quad (2)$$

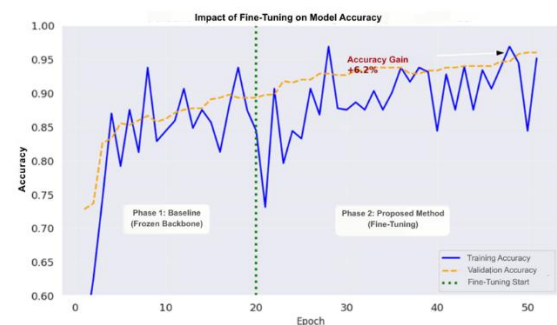
Heatmap ini kemudian di-overlay pada citra asli untuk menunjukkan area fokus model secara intuitif, memberikan wawasan interpretatif yang serupa dengan analisis morfologis pada studi klasifikasi ikan oleh Lima (Lima, S. A., 2024)

3. PEMBAHASAN

Hasil penelitian ini sejalan dengan tren efisiensi dalam computer vision modern. dibandingkan dengan pendekatan tradisional yang hanya mengandalkan analisis warna (Teresa et al., 2023) atau larik sensor fluoresen yang memerlukan perangkat keras tambahan (Lin et al., 2024), model deep learning kami menawarkan solusi end-to-end yang lebih praktis. Lebih jauh, akurasi 96.01% yang dicapai mobilenetv2 terbukti kompetitif tidak hanya terhadap model daging sapi lainnya, tetapi juga jika dibandingkan dengan studi pada komoditas lain, seperti deteksi kesegaran dada ayam oleh jian et al. (Jian et al., 2025) dan bubuk cabai oleh brar et al. (Brar et al., 2025), yang menggunakan arsitektur lebih berat. Keunggulan mobilenetv2 terletak pada penggunaan inverted residuals yang secara signifikan mengurangi parameter dibandingkan model scaling standar seperti efficientnet (tan & le, 2019), menjadikannya kandidat ideal untuk implementasi low-resource.

3.1. Kinerja Pelatihan Model

Model dilatih menggunakan strategi two-phase training yang dimulai dengan pembekuan base model dan dilanjutkan dengan fine-tuning. Gambar 2 menunjukkan kurva pembelajaran yang dihasilkan. Terlihat bahwa akurasi validasi mengalami peningkatan signifikan dan stabil setelah memasuki fase fine-tuning (setelah epoch 20), membuktikan efektivitas strategi ini dalam mengadaptasi fitur model pralatih ke domain citra daging. Fenomena konvergensi yang stabil pada arsitektur MobileNetV2 ini sejalan dengan temuan Muttaqin dan Arifudin pada klasifikasi kesegaran buah, di mana fine-tuning lapisan atas terbukti krusial untuk menangkap fitur spesifik dataset yang lebih kecil. (Muttaqin & Arifudin, 2024)



Gambar 2. Kurva akurasi pelatihan dan validasi dengan strategi fine-tuning

3.2. Evaluasi Kuantitatif

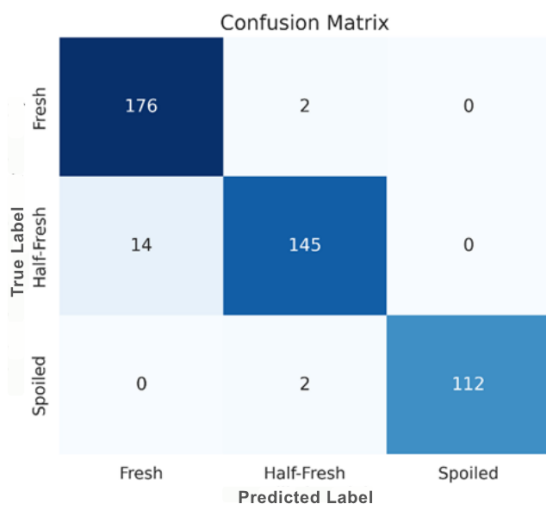
Tabel 1 menyajikan distribusi data yang digunakan. Meskipun terdapat sedikit ketidakseimbangan kelas

(imbalanced), model berhasil mempelajari karakteristik tiap kelas dengan baik. Isu ketidakseimbangan ini merupakan tantangan umum dalam dataset pangan seperti yang diulas dalam survei komprehensif oleh Gilal et al. (Gilal et al., 2024), namun dapat dimitigasi melalui teknik augmentasi yang tepat.

**Tabel 1. Distribusi dataset gambar daging**

Class	Training	Valid	Total (Images)
Fresh	675	178	853
Spoiled	510	114	624
Half-Fresh	630	159	789
Total (Split)	1815	451	2266

Hasil evaluasi pada data uji menggunakan Confusion Matrix (Gambar 3) menunjukkan performa yang sangat kuat dengan akurasi total 96.01%. Yang paling krusial, nilai presisi untuk kelas Spoiled mencapai 1.00 (100%), yang berarti tidak ada daging busuk yang salah diprediksi sebagai segar. Dalam konteks keamanan pangan, meminimalkan false negative adalah prioritas utama untuk mencegah risiko kesehatan, sebuah standar yang juga ditekankan dalam studi keamanan pangan global oleh Gbashi dan Njobeh (Gbashi & Njobeh, 2024)



**Gambar 3. Hasil evaluasi pada data uji menggunakan Confusion Matrix**

Laporan klasifikasi lengkap pada Tabel 2 mempertegas hasil ini. Nilai presisi untuk kelas Spoiled mencapai 1.00 (100%), yang berarti setiap kali model memprediksi daging itu busuk, prediksinya selalu benar. Hal ini sangat krusial untuk sistem keamanan pangan untuk meminimalkan risiko meloloskan produk berbahaya.

**Tabel 2. Performa model klasifikasi**


Jika dibandingkan dengan metode Deep Learning lain, performa MobileNetV2 kami (96.01%) sangat

Class	Precision	Recall	F1-Score	Jumlah Data (Support)
Fresh	0.9263	0.9888	0.9565	178
Half-Fresh	0.9732	0.9119	0.9416	159
Spoiled	1.000	0.9825	0.9912	114
Accuracy (Total)			0.9601	451
Macro Avg	0.9665	0.9611	0.9631	451
Weighted Avg	0.9615	0.9601	0.9600	451

kompetitif terhadap model yang jauh lebih kompleks seperti Ensemble CNN yang diusulkan Elangovan et al. (Elangovan et al., 2024) atau arsitektur ResNet-50 yang digunakan Koh dan Kim (Koh & Kim, 2025) untuk prediksi kualitas daging, namun dengan keuntungan efisiensi komputasi yang jauh lebih tinggi.

**3.3. Analisis Transparansi dengan Grad-CAM**


Penggunaan XAI memberikan validasi kualitatif terhadap keputusan model. Gambar 4 menunjukkan visualisasi Grad-CAM pada prediksi yang benar. Untuk kelas Fresh, heatmap berfokus pada area otot (lean meat) yang menunjukkan tekstur serat, sementara pada kelas Spoiled, model menyorot area perubahan warna. Hal ini mengonfirmasi bahwa model mempelajari representasi fitur yang benar secara biologis, bukan sekadar menghafal latar belakang. Temuan ini memperkuat hasil studi Lima pada klasifikasi ikan, di mana Grad-CAM berhasil mengidentifikasi fitur morfologis vital. (Lima, S. A., 2024) Pendekatan visualisasi otomatis ini juga menawarkan keunggulan dibandingkan metode interpretasi manual berbasis fitur statistik (seperti GLCM) yang digunakan dalam studi bubuk buah oleh Przybył [2024], karena mampu menangkap fitur semantik yang lebih kompleks secara langsung dari raw image. Pentingnya transparansi ini sangat ditekankan dalam tinjauan Arrighi et al. sebagai syarat utama adopsi AI di industri yang teregulasi ketat. (Zullich et al., n.d.)



**Gambar 4. Visualisasi Grad-CAM untuk prediksi benar (atas : fresh, Tengah: half-fresh, bawah: spoiled)**

### 3.4. Analisis Kesalahan (Failure Analysis)

Meskipun performa tinggi, analisis heatmap pada kasus kesalahan (Gambar 5) mengungkapkan bahwa model terkadang bias terhadap area lemak berwarna putih bersih, menganggapnya sebagai indikator kesegaran meskipun area otot di sekitarnya mulai kusam. Bias visual semacam ini adalah tantangan umum dalam supervised learning. Namun, dengan integrasi analitik Big Data di masa depan sebagaimana disarankan oleh Siddique et al., dataset dapat diperkaya secara dinamis untuk mencakup variasi potongan lemak yang lebih beragam, sehingga meningkatkan robustitas model. (Siddique et al., 2025)



**Gambar 5. Analisis GRAD-CAM dalam kasus salah prediksi**

## 4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem deteksi kesegaran daging sapi berbasis Deep Learning yang akurat dan dapat dijelaskan (explainable). Dengan memanfaatkan Transfer Learning pada MobileNetV2, model mencapai akurasi 96.01% dan presisi sempurna (100%) untuk kelas daging busuk, sebuah metrik krusial untuk memitigasi risiko keamanan pangan. Integrasi Grad-CAM membuktikan bahwa model mengambil keputusan berdasarkan fitur visual biologis yang relevan (tekstur dan warna), bukan noise, menjawab tantangan transparansi (black-box) yang sering menghambat adopsi AI. Temuan ini mendukung potensi implementasi sistem pada perangkat mobile

untuk pemantauan rantai pasok yang lebih tangguh (Jauhar et al., 2024) Saran untuk penelitian selanjutnya adalah memperluas dataset dengan variasi potongan lemak yang lebih ekstrem dan mengintegrasikan model ke dalam aplikasi berbasis Internet of Things (IoT).

## PUSTAKA

- Regita, Z., & Daspar, D. (2025). Analisis Peluang dan Tantangan Perdagangan Internasional Komoditas Peternakan antara Indonesia dan Australia dalam Kerangka APEC. *Kompeten: Jurnal Ilmiah Ekonomi dan Bisnis*, 4(1), 1260–1267. <https://doi.org/10.57141/kompeten.v4i1.199>
- Brar, D. S., Singh, B., & Nanda, V. (2025). *Sustainable Food Technology variety of red chilli powder*. 1099–1113. <https://doi.org/10.1039/d5fb00118h>
- Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (n.d.). *Visual Explanations from Deep Networks via Gradient-based Localization*.
- Elangovan, P., Dhurairajan, V., Nath, M. K., & Yogarajah, P. (2024). *applied sciences A Novel Approach for Meat Quality Assessment Using an Ensemble of Compact Convolutional Neural Networks*.
- Gbashi, S., & Njobeh, P. B. (2024). Enhancing Food Integrity through Artificial Intelligence and Machine Learning: A Comprehensive Review. *Applied Sciences (Switzerland)*, 14(8). <https://doi.org/10.3390/app14083421>
- Gilal, N. U., Al-Thelaya, K., Al-Saeed, J. K., Abdallah, M., Schneider, J., She, J., Awan, J. H., & Agus, M. (2024). Evaluating machine learning technologies for food computing from a data set perspective. *Multimedia Tools and Applications*, 83(11), 32041–32068. <https://doi.org/10.1007/s11042-023-16513-4>
- Hidayatulloh, S., Mustajab, M. A., & Ramdhani, Y. (2023). Penggunaan Optimasi Atribut Dalam Peningkatan Akurasi Prediksi Deep Learning Pada Bike Sharing Demand. *INFOTECH Journal*, 9(1), 54–61. <https://doi.org/10.31949/infotech.v9i1.4530>
- Jauhar, S. K., Harinath, S., Krishnaswamy, V., & Paul, S. K. (2024). Explainable artificial intelligence to improve the resilience of perishable product supply chains by leveraging customer characteristics. In *Annals of Operations Research*. Springer US. <https://doi.org/10.1007/s10479-024-06348-z>
- Jayan, H., Min, W., & Guo, Z. (2025). Applications of Artificial Intelligence in Food Industry. *Foods*, 14(7), 1–6. <https://doi.org/10.3390/foods14071241>
- Jian, R., Li, G., Jun, X., & Shi, G. (2025). *Nondestructive freshness recognition of chicken breast meat based on deep learning*. 1–19.

- Kılıçarslan, S., Hiz Çiçekliyurt, M. M., & Kılıçarslan, S. (2024). Fish Freshness Detection Through Artificial Intelligence Approaches: A Comprehensive Study. *Turkish Journal of Agriculture - Food Science and Technology*, 12(2), 290–295. <https://doi.org/10.24925/turjaf.v12i2.290-295.6670>
- Koh, M. J., & Kim, H. S. (2025). Deep learning-based image analysis techniques for fresh meat quality prediction. 1(3), 111–124.
- Lee, I. H., & Ma, L. (2025). Integrating machine learning, optical sensors, and robotics for advanced food quality assessment and food processing. *Food Innovation and Advances*, 4(1), 65–72. <https://doi.org/10.48130/fia-0025-0007>
- Lin, Y., Ma, J., Sun, D., Cheng, J., & Zhou, C. (2024). Fast real-time monitoring of meat freshness based on fluorescent sensing array and deep learning : From development to deployment. 448(March). <https://doi.org/10.1016/j.foodchem.2024.139078>
- Mostafa, S., Mondal, D., Panjvani, K., Kochian, L., & Stavness, I. (2023). Explainable deep learning in plant phenotyping. *Frontiers in Artificial Intelligence*, 6(2020). <https://doi.org/10.3389/frai.2023.1203546>
- Muttaqin, I. F., & Arifudin, R. (2024). Fruit Freshness Detection Using Android-Based Transfer Learning MobileNetV2. *Recursive Journal of Informatics*, 2(1), 8–17. <https://doi.org/10.15294/rji.v2i1.70845>
- Przybył, K. (2024). Explainable AI: Machine Learning Interpretation in Blackcurrant Powders. *Sensors*, 24(10). <https://doi.org/10.3390/s24103198>
- Salma, S., Habib, M., Tannouche, A., & Ounejjar, Y. (2023). *Revue d ' Intelligence Artificielle Poultry Meat Classification Using MobileNetV2 Pretrained Model*. 37(2), 275–280.
- Sandler, M., Howard, A., Zhu, M., & Zhmoginov, A. (n.d.). *MobileNetV2 : Inverted Residuals and Linear Bottlenecks*. 4510–4520.
- Siddique, A., Gupta, A., Sawyer, J. T., Huang, T., & Morey, A. (2025). Big data analytics in food industry : a state- of-the-art literature review Check for updates. *Npj Science of Food*. <https://doi.org/10.1038/s41538-025-00394-y>
- Tan, M., & Le, Q. V. (2019). *EfficientNet : Rethinking Model Scaling for Convolutional Neural Networks*.
- Teresa, M., Claudia, N. S., Domínguez-soberanes, J., & Alvarez-cisneros, Y. M. (2023). *Heliyon Analysis of beef quality according to color changes using computer vision and white-box machine learning techniques*. 9(November 2022), 0–11. <https://doi.org/10.1016/j.heliyon.2023.e17976>
- Lima, S. A. (2024). Interpretable Fish Classification through MobileNetV2 and Grad-CAM Visualization. *International Journal of Research in Engineering, Science and Management*, 7(9), 93–99. <https://journal.ijresm.com/index.php/ijresm/article/view/3183>
- Zhao, F., Wei, Z., Bai, Y., Li, C., Zhou, G., Kristiansen, K., & Wang, C. (2022). *Proteomics and Metabolomics Profiling of Pork Exudate Reveals Meat Spoilage during Storage*.
- Zullich, M., Barbin, D. F., & Simonato, M. (n.d.). *EXPLAINABLE ARTIFICIAL INTELLIGENCE TECHNIQUES FOR INTERPRETATION OF FOOD DATASETS : A REVIEW*. 1–33.