



Tersedia Online : <http://e-journals.unmul.ac.id/>

ADOPSI TEKNOLOGI DAN SISTEM INFORMASI (ATASI)

Alamat Jurnal : <http://e-journals2.unmul.ac.id/index.php/atasi/index>



Klasifikasi Kesegaran Ikan Pada Citra dengan VGG19

Arisda Dwi Putri ¹⁾, Faisal Fajri Rahani ^{2)*}

^{1,2)}Program Studi Informatika, Fakultas Teknologi Industri, Universitas Ahmad Dahlan

E-Mail : arisda1800018239@wemail.uad.ac.id¹⁾; faisal.fajri@tif.uad.ac.id²⁾

ARTICLE INFO

Article history:

Received : 05 May 2025

Revised : 07 May 2025

Accepted : 16 May 2025

Available online : 10 June 2025

Keywords:

Freshness of Fish
Transfer Learning
CNN
VGG19

ABSTRACT

It is widely accepted that fish constitutes a highly nutritious and protein-rich food source for the human body. As a consumer, it is imperative to select high-quality fish for consumption, whether for oneself or one's family, a consideration that assumes particular significance for mothers with children in the growth phase. The quality and nutritional value of fish are significantly impacted by its freshness. Furthermore, the consumption of non-fresh fish has been associated with the risk of poisoning and potential digestive health complications. This research adopts the Convolutional Neural Network (CNN) algorithm and Transfer Learning approach to perform fish freshness classification based on digital images. The VGG19 network is analogous to the AlexNet architecture, with successive convolutional layers comprising an increasing number of filters as the network becomes more deeply convoluted. The objective of the research is to devise a system that is anticipated to surmount the issue of categorising the freshness level by employing CNN with a transfer learning approach. The performance of the system is evaluated by calculating various evaluation metrics, including accuracy, precision, recall and f1-score. These metrics are determined using the confusion matrix method, which is a statistical technique used to analyse the performance of a classification system. The process of evaluating the performance involves identifying the optimal value of these metrics, which is determined through the application of various statistical analysis techniques. The results of this study are a fish freshness classification system using two models, namely Convolutional Neural Network (CNN) and VGG19N with transfer learning. The employment of 1220 image data resulted in an accuracy value of 86% for the VGG19 model.

ABSTRAK

Ikan merupakan sumber makanan yang sangat bernutrisi dan berprotein tinggi untuk tubuh manusia. Sebagai konsumen, memilih ikan dengan mutu yang baik untuk dikonsumsi baik oleh diri sendiri atau keluarga sangatlah penting, apalagi bagi ibu-ibu yang memiliki anak-anak yang masih dalam masa pertumbuhan. Ikan yang tidak segar memengaruhi rasa dan nutrisi dari ikan tersebut, bahkan dapat membuat keracunan dan memengaruhi kesehatan pencernaan konsumen. Penelitian ini mengadopsi algoritma *Convolutional Neural Network* (CNN) dan pendekatan *Transfer Learning* untuk melakukan klasifikasi tingkat kesegaran ikan berdasarkan citra digital. Jaringan VGG19 seperti arsitektur *AlexNet*, dengan lapisan konvolusional berurutan dengan filter yang semakin meningkat saat masuk lebih dalam ke dalam jaringan. Penelitian bertujuan untuk membuat sebuah sistem yang diharapkan dapat mengatasi permasalahan tentang mengklasifikasikan tingkat kesegaran dengan menggunakan CNN dengan pendekatan *transfer learning*. Evaluasi performa dilakukan dengan menghitung *accuracy*, *precision*, *recall*, *f1-score* menggunakan metode *confusion matrix*, untuk mencari nilai terbaik. Hasil dari penelitian ini adalah sistem klasifikasi kesegaran ikan menggunakan dua model yaitu *Convolutional Neural Network* (CNN) dan VGG19 dengan *transfer learning*. Pengujian dengan menggunakan 1220 data citra diperoleh nilai akurasi sebesar 86% untuk model VGG19.

2025 Adopsi Teknologi dan Sistem Informasi (ATASI) with CC BY SA license.

Kata Kunci :

Kesegaran Ikan
Transfer Learning
CNN
VGG19

APA style in citing this article:

A. D. Putri and F. F. Rahani,
"Klasifikasi Kesegaran Ikan
Pada Citra dengan VGG19,"
ATASI: Adopsi Teknologi dan
Sistem Informasi, vol. 4, no. 1,
pp. 1–7, 2025.
<https://doi.org/10.30872/atasi.v4i1.2888>

*) Corresponding Author

<https://doi.org/10.30872/atasi.v4i1.2888>

2025 Adopsi Teknologi dan Sistem Informasi (ATASI) with CC BY SA license.

1. PENDAHULUAN

Ikan merupakan sumber makanan yang sangat bernutrisi dan berprotein tinggi untuk tubuh manusia, ikan juga salah satu makanan yang paling diminati masyarakat Indonesia, dalam survey konsumsi makanan dari masyarakat Indonesia oleh Badan Pusat Statistik (BPS) pada tahun 2015, ikan menempati peringkat keempat. Indonesia merupakan negara kepulauan yang diapit oleh dua samudra yaitu samudra Hindia dan Pasifik, Indonesia memiliki banyak sekali jenis ikan dari ikan air laut hingga ikan air tawar. Tetapi ikan merupakan hewan air yang gampang rusak setelah di tangkap atau di panen dari air apabila salah penanganan, jika penanganan ikan salah maka kesegaran dari ikan tersebut akan menurun dan akan berpengaruh pada kualitas dari ikan.

Pada umumnya ikan yang diperjual-belikan di pasar merupakan ikan segar, namun tidak sedikit ditemukan beberapa ikan yang sudah tidak lagi segar, seperti berupa ikan yang telah lama diawetkan dengan es (Prasetyo et al., 2021). Ikan yang dipasarkan harus memenuhi ketentuan yang terdapat pada Standar Nasional Indonesia Nomor 012729.1 Tahun 2006 tentang spesifikasi ikan segar. Pada SNI 01-2729.1-2006 tentang spesifikasi ikan segar dijelaskan kesegaran ikan dapat dilihat dari bagian ikan tersebut seperti mata ikan yang cerah, warna insang masih berwarna merah, ikan berlendir bening, daging ikan bertekstur kenyal dan padat, bentuk ikan, sisik masih menempel dan juga ikan tidak berbau aneh (Jerandu et al., 2022). Sebagai konsumen, memilih ikan dengan mutu yang baik untuk dikonsumsi baik oleh diri sendiri atau keluarga sangatlah penting, apalagi bagi ibu-ibu yang memiliki anak-anak yang masih dalam masa pertumbuhan. Ikan yang tidak segar memengaruhi rasa dan nutrisi dari ikan tersebut, bahkan dapat membuat keracunan dan memengaruhi kesehatan pencernaan konsumen.

Klasifikasi berbasis citra merupakan teknik yang penting dalam pengidentifikasian dan pengelompokan objek dalam gambar, termasuk dalam konteks pemantauan kualitas ikan. Ikan adalah sumber makanan bernutrisi dan berprotein tinggi yang sangat diminati masyarakat Indonesia, dan pemilihan ikan segar sangat penting untuk kesehatan, terutama bagi anak-anak yang sedang dalam masa pertumbuhan. Berbagai metode klasifikasi citra yang tersedia, seperti pengolahan citra tradisional (Jerandu et al., 2022), *machine learning* (Kassania et al., 2021), Convolutional Neural Networks (CNN) (Thakur et al., 2023), dan VGG (Sitaula & Hossain, 2021), menawarkan pendekatan yang berbeda dalam analisis citra ikan.

Pengolahan citra tradisional sederhana tetapi kurang efektif dalam menangkap fitur kompleks, sementara *machine learning* membutuhkan ekstraksi fitur yang tepat. Di sisi lain, CNN dapat secara otomatis mengenali pola dalam gambar, menawarkan akurasi tinggi, dan VGG dengan arsitektur yang lebih dalam mampu menganalisis detail yang sangat halus (Mouton et al., 2020). Dengan menggunakan metode CNN dan VGG, kita dapat melatih model untuk mengevaluasi indikator kesegaran ikan, seperti kondisi mata, warna insang, dan tekstur daging. Penggunaan kedua metode ini, ketika dilengkapi dengan dataset yang memadai, dapat menghasilkan sistem klasifikasi yang efektif untuk menilai kesegaran ikan, sehingga membantu konsumen dalam memilih ikan berkualitas baik dan aman untuk dikonsumsi.

Penelitian bertujuan untuk mengetahui kesegaran ikan, pada penelitian ini penulis memanfaatkan pengolahan citra digital, pengolahan citra itu sendiri digunakan untuk proses pengenalan objek, metode yang digunakan yaitu metode *Convolutional Neural Network* (CNN) yang saat ini memiliki tingkat keakuratan tinggi seperti deteksi obyek. Dari penelitian ini untuk mengetahui tingkat kesegaran ikan dibagi kedalam tiga kelas yaitu, segar, tidak segar, dan busuk.

2. TINJAUAN PUSAKA

Penelitian terkait klasifikasi kesegaran ikan menggunakan metode Convolutional Neural Networks (CNN). Penelitian pertama menunjukkan bahwa VGG16 mencapai akurasi tertinggi (0,97) dalam klasifikasi kesegaran ikan bandeng berdasarkan citra mata, menyoroti pentingnya pemilihan ikan segar oleh konsumen (Prasetyo et al., 2021). Penelitian kedua berhasil membedakan ikan segar dan tidak segar dengan akurasi 100% pada data training dan testing, menunjukkan efektivitas CNN dalam identifikasi kesegaran ikan (Agustyan, 2020). Penelitian ketiga berfokus pada citra insang, mengklasifikasikan ikan menjadi tiga kelas (segar, tidak segar, busuk) dengan akurasi 97,7% pada data testing (Sholihin & Rosidi Zamroni, 2021). Penelitian keempat menggunakan Deep CNN untuk mendeteksi kesegaran ikan sarden, mencapai hasil akurasi yang luar biasa dalam berbagai metrik evaluasi (Lestari et al., 2015). Selanjutnya, penelitian kelima menganalisis tingkat kesegaran ikan di Pasar Minggu Kota Bengkulu berdasarkan SNI 01-2729.1-2006, yang menunjukkan penurunan kesegaran ikan sepanjang hari dan mencatat kerusakan fisik pada berbagai jenis ikan. Keseluruhan penelitian ini mendemonstrasikan potensi metode berbasis citra dan teknik deep learning bagi konsumen dalam menilai kualitas dan kesegaran ikan.

A. Deep Learning

Deep Learning (DL) ialah subbidang ilmu yang menggunakan kumpulan data yang sangat besar dan didasarkan pada Pembelajaran Mesin berbasis jaringan saraf tiruan. *Deep Learning* merupakan salah satu metode implementasi dari *Machine Learning* yang bertujuan untuk meniru cara kerja otak manusia menggunakan Artificial Neural Network atau jaringan nalar buatan (Wang et al., 2020). Model pembelajaran dapat merepresentasikan gambar berlabel dengan lebih baik ketika lebih banyak lapisan ditambahkan.

B. Convolutional Neural Networks (CNN)

Convolutional Neural Network (CNN) adalah pengembangan *MultiLayer Perceptron* (MLP) dari pengolahan data dua dimensi (2D). Model CNN memodifikasi arsitektur Jaringan Saraf Tiruan (JSP) agar dapat langsung

<https://doi.org/10.30872/atasi.v4i1.2888>

The diagram illustrates a deep convolutional neural network (CNN) architecture for image classification. It starts with an **Input** of size 48×48 . This is followed by a **Convolution** layer producing **Feature Maps** of size $6 @ 44 \times 44$. These are then processed by a **Max-pooling** layer. The next stage is another **Convolution** layer producing **Feature Maps** of size $12 @ 22 \times 22$, followed by another **Max-pooling** layer. This is followed by a third **Convolution** layer producing **Feature Maps** of size $12 @ 18 \times 18$, and finally a fourth **Convolution** layer producing **Feature Maps** of size $12 @ 9 \times 9$. The output of the final convolution layer is fed into a **Classification** layer, which uses a fully connected network to output the final classification results. The entire process from input to the final classification layer is labeled as **Features extraction**.

1) Convolution Layers

2) Pooling Layers

3) Full Connection Layers

C. Transfer Learning

D. VGG19

The diagram illustrates the proposed CNN architecture. It starts with an 'Input Image' box on the left, followed by a sequence of layers represented by colored rectangles. The layers are: two orange rectangles (3x3 Conv (64)), two green rectangles (3x3 Conv (128)), two grey rectangles (2x2 maxPooling), three purple rectangles (3x3 Conv (256)), one dark grey rectangle (2x2 maxPooling), five pink rectangles (3x3 Conv (512)), one dark grey rectangle (2x2 maxPooling), four pink rectangles (3x3 Conv (512)), one dark grey rectangle (2x2 maxPooling), and three white rectangles (Full connection). The sequence ends with an 'Output' box on the right. A legend at the bottom identifies the colors: orange for 3x3 Conv (64), green for 3x3 Conv (128), purple for 3x3 Conv (256), pink for 3x3 Conv (512), dark grey for 2x2 maxPooling, and white for Full connection.

<https://doi.org/10.30872/atasi.v4i1.2888>
2025 Adopsi Teknologi dan Sistem Informasi (ATASI) with CC BY SA license.

3. METODE PENELITIAN

Proses penelitian ini bertujuan untuk mendapatkan hasil dari penelitian, tahapan-tahapan penelitian terdiri atas pengumpulan data, *preprocessing*, perancangan, dan pengujian ditunjukkan pada Gambar 3.




Gambar 3. Proses penelitian

A. Pengumpulan Data Citra

Pada fase ini, peneliti akan melakukan pencarian dan pengumpulan informasi citra yang akan digunakan dalam penelitian. Proses pengumpulan data mencakup citra ikan yang dicari dan diambil dari hasil pengamatan melalui pencarian di internet serta situs-situs seperti Kaggle atau Google Images.

B. Preprocessing

Setelah mendapatkan informasi yang diperlukan, langkah selanjutnya adalah melakukan tahap pra-pemrosesan melalui pemotongan dan perubahan ukuran gambar. Pemotongan bertujuan untuk mengekstrak objek kerusakan pada ikan. Proses berikutnya melibatkan pengelompokan data di mana informasi yang dikumpulkan akan dibagi menjadi data pelatihan dan data pengujian. Contoh hasil pemotongan pada citra bisa dilihat pada Gambar 4.



Gambar 4. Preprocessing data

Pada *cropping* dilakukan pemotongan citra, proses ini bertujuan untuk lebih memfokuskan pada ikan.

C. Pembuatan Jaringan

Arsitektur yang digunakan pada penelitian adalah VGG19. VGG19 merupakan jaringan saraf konvolusional yang memiliki kedalaman 19 lapisan (16 lapisan konvolusional dan 3 lapisan terhubung penuh) untuk mengklasifikasi gambar kedalam 1000 kategori objek, VGG19 dilatih pada basis data *ImageNet* yang berisi satu juta gambar dari 1000 kategori. Pada penelitian ini menggunakan VGG19 dengan metode transfer learning tanpa proses pembelajaran ulang dari awal.


D. Pengujian Model

Pada fase ini, tujuan utama adalah untuk mengevaluasi seberapa tepat model Convolution Neural Network (CNN) VGG19 yang menggunakan teknik *transfer learning*. Beberapa parameter akan diubah agar diperoleh data akurasi yang optimal.

E. Hasil Penelitian

Pada fase ini, studi bertujuan seperti yang telah dijelaskan pada fase sebelumnya, yaitu untuk mengukur seberapa akurat model CNN VGG 19. Akurasi menjadi indikator dari hasil klasifikasi data; semakin rendah akurasi yang diperoleh, maka semakin tepat klasifikasi data tersebut dan sebaliknya. Berdasarkan struktur CNN VGG 19 yang diterapkan untuk mengidentifikasi tingkat kesegaran ikan, tujuan utamanya adalah untuk dapat mendeteksi dan mengklasifikasikan tingkat kesegaran ikan dengan baik.

4. HASIL DAN PEMBAHASAN




Gambar 5. Grafik training

Grafik Gambar 5 menunjukkan akurasi pelatihan (*Training Accuracy*) dan akurasi validasi (*Validation Accuracy*) terhadap jumlah epoch dalam proses pelatihan model machine learning (kemungkinan model klasifikasi). Sumbu X (horizontal) menunjukkan jumlah epoch (jumlah iterasi penuh melalui dataset pelatihan). Sumbu Y (vertikal): Menunjukkan akurasi (nilai antara 0 hingga 1, atau 0% hingga 100%). Garis biru menunjukkan akurasi pelatihan seberapa baik model belajar pada data pelatihan. Garis oranye menunjukkan akurasi validasi seberapa baik model menggeneralisasi pada data yang tidak dilatih (digunakan untuk evaluasi).

Gambar 5 menunjukkan kurva akurasi pelatihan dan validasi dari model klasifikasi selama 25 epoch pelatihan. Berdasarkan grafik tersebut, terlihat bahwa akurasi pelatihan meningkat tajam sejak awal pelatihan dan mencapai nilai mendekati 100% sebelum epoch ke-10. Epoch 0 hingga 5 terjadi peningkatan akurasi yang signifikan, baik pada pelatihan maupun validasi. Tren yang serupa juga ditunjukkan oleh akurasi validasi, yang mengalami peningkatan signifikan pada awal pelatihan dan kemudian tetap stabil pada kisaran nilai yang sangat tinggi, mendekati akurasi pelatihan. Kesesuaian antara akurasi pelatihan dan validasi ini mengindikasikan bahwa model mampu melakukan generalisasi dengan baik terhadap data yang tidak dilatih, tanpa menunjukkan gejala *overfitting*. Selain itu, stabilnya kurva setelah epoch ke-10 menandakan bahwa model telah mencapai konvergensi secara cepat.

Hasil ini menunjukkan bahwa model memiliki performa klasifikasi yang sangat baik dan efisien dalam proses pembelajarannya. Tidak terlihat indikasi *overfitting* yang jelas karena akurasi validasi tetap tinggi dan sejalan dengan akurasi pelatihan. Model sudah konvergen (berhenti meningkat signifikan) sebelum epoch ke-10. Model memiliki performa sangat baik, cepat belajar, dan menunjukkan kemampuan generalisasi yang kuat terhadap data validasi, yang artinya model tidak hanya menghafal data pelatihan tetapi juga bisa diterapkan ke data baru.



Gambar 6. Grafik Nilai Loss

Grafik Gambar 6 menunjukkan nilai loss (kerugian) untuk data pelatihan dan validasi selama 25 epoch dalam proses pelatihan model. Sumbu X (horizontal) jumlah epoch (iterasi pelatihan). Sumbu Y (vertikal) loss ukuran

kesalahan prediksi model (semakin rendah semakin baik). Garis biru menunjukkan training loss kesalahan model pada data pelatihan. Garis oranye menunjukkan validation loss kesalahan model pada data validasi.

Gambar 6 menunjukkan kurva loss untuk data pelatihan dan validasi selama 25 epoch. Berdasarkan grafik tersebut, terlihat bahwa nilai loss pada kedua data mengalami penurunan yang sangat signifikan pada lima epoch pertama, yang mengindikasikan proses pembelajaran awal yang efektif. Pada 5 epoch pertama, terjadi penurunan yang sangat tajam baik pada *training loss* maupun *validation loss*, menunjukkan bahwa model belajar dengan cepat dari data. Selanjutnya, baik *training loss* maupun *validation loss* terus menurun dan mencapai nilai yang sangat rendah mendekati nol setelah sekitar epoch ke-10, serta tetap stabil hingga akhir pelatihan. Setelah sekitar epoch ke-10, nilai loss baik pada pelatihan maupun validasi mendekati nol dan relatif stabil, menunjukkan konvergensi model.

Stabilitas dan kedekatan antara kedua kurva loss ini menunjukkan bahwa model telah mencapai konvergensi dan mampu melakukan generalisasi dengan baik terhadap data validasi. Tidak terlihat adanya peningkatan loss pada data validasi, yang menandakan tidak terjadi *overfitting* selama pelatihan. Secara keseluruhan, hasil ini mengindikasikan bahwa model memiliki tingkat kesalahan prediksi yang sangat rendah dan performa pembelajaran yang efisien. Model menunjukkan performa pembelajaran yang sangat baik dengan laju konvergensi yang cepat. Nilai loss yang rendah dan stabil pada pelatihan maupun validasi mengindikasikan bahwa model tidak hanya akurat tetapi juga konsisten dan generalizable terhadap data baru.

Classification Report				
	precision	recall	f1-score	support
Segar	0.67	0.96	0.79	712
Tidak Segar	0.86	0.35	0.50	508
accuracy			0.71	1220
macro avg	0.77	0.65	0.64	1220
weighted avg	0.75	0.71	0.67	1220

Gambar 7. Classification Report

Gambar tersebut merupakan *classification report* yang menunjukkan performa model klasifikasi dalam membedakan dua kelas, yaitu Segar dan Tidak Segar. Laporan ini berisi beberapa metrik evaluasi penting: *precision*, *recall*, *f1-score*, dan *support* untuk masing-masing kelas. *Precision*: Proporsi prediksi positif yang benar (seberapa akurat model saat memprediksi suatu kelas). *Recall*: Proporsi aktual positif yang berhasil diprediksi dengan benar (seberapa baik model menangkap semua data positif). *F1-Score*: *Harmonic mean* dari *precision* dan *recall*; memberikan gambaran umum keseimbangan antara keduanya. *Support*: Jumlah sampel sebenarnya di setiap kelas.

Hasil evaluasi performa model klasifikasi ditunjukkan pada Tabel 1. Untuk kelas "Segar", model mencapai *precision* sebesar 0,67, yang berarti 67% dari seluruh prediksi "Segar" adalah benar, serta *recall* sebesar 0,96, menunjukkan bahwa 96% dari semua data "Segar" berhasil dikenali dengan benar. Nilai *f1-score* untuk kelas ini tercatat sebesar 0,79, yang mencerminkan keseimbangan yang cukup baik antara *precision* dan *recall*. Sementara itu, untuk kelas "Tidak Segar", model memperoleh *precision* sebesar 0,86, menunjukkan tingkat keakuratan prediksi yang tinggi, namun *recall*-nya hanya mencapai 0,35, yang berarti hanya 35% dari seluruh data "Tidak Segar" yang berhasil terdeteksi. *F1-score* untuk kelas ini sebesar 0,50, yang menunjukkan keseimbangan *precision* dan *recall* yang lebih rendah dibandingkan dengan kelas "Segar". Secara keseluruhan, akurasi model mencapai 0,71, yang berarti 71% dari seluruh prediksi model adalah benar. Selain itu, nilai *macro average precision*, *recall*, dan *f1-score* masing-masing sebesar 0,77, 0,65, dan 0,64, sedangkan *weighted average precision*, *recall*, dan *f1-score* masing-masing sebesar 0,75, 0,71, dan 0,67. Nilai-nilai ini mengindikasikan bahwa model menunjukkan performa yang cukup baik, meskipun masih terdapat ketidakseimbangan dalam mendeteksi kedua kelas.

5. KESIMPULAN

Berdasarkan hasil analisis terhadap grafik akurasi, grafik loss, dan laporan klasifikasi, dapat disimpulkan bahwa model klasifikasi yang dikembangkan menunjukkan performa yang sangat baik selama proses pelatihan dan validasi. Grafik akurasi menunjukkan peningkatan yang cepat dan stabil hingga mencapai nilai mendekati 100% sebelum epoch ke-10, baik pada data pelatihan maupun validasi, tanpa adanya indikasi *overfitting*. Hal ini menandakan bahwa model mampu melakukan generalisasi dengan baik terhadap data yang belum pernah dilihat sebelumnya. Selain itu, grafik loss memperlihatkan penurunan nilai loss yang tajam pada awal pelatihan dan stabil pada nilai yang sangat rendah setelah sekitar epoch ke-10, mengindikasikan bahwa model mencapai konvergensi dengan cepat dan efektif.

Hasil *classification report* mendukung temuan ini dengan akurasi keseluruhan sebesar 71%. Model menunjukkan kemampuan yang sangat baik dalam mendeteksi kelas "Segar" (*recall* tinggi sebesar 96%), namun performa dalam mendeteksi kelas "Tidak Segar" masih perlu ditingkatkan, terlihat dari nilai *recall* yang relatif rendah sebesar 35%. Meskipun terdapat ketidakseimbangan dalam kinerja antar kelas, nilai *macro average* dan *weighted average* dari *precision*, *recall*, dan *f1-score* tetap berada pada tingkat yang cukup baik.

Secara keseluruhan, model ini dinilai efektif dan efisien dalam proses pembelajaran, menunjukkan kemampuan klasifikasi yang tinggi, serta mampu menggeneralisasi dengan baik terhadap data validasi. Perbaikan lebih lanjut dapat difokuskan pada peningkatan deteksi terhadap kelas minoritas untuk meningkatkan keseimbangan performa antar kelas.

6. DAFTAR PUSTAKA

- Agustyawan, A. (2020). Pengolahan Citra untuk Membedakan Ikan Segar dan Tidak Segar Menggunakan Convolutional Neural Network. *IJAI (Indonesian Journal of Applied Informatics)*, 5(1), 11–19. <https://doi.org/10.20961/IJAI.V5I1.41770>
- Ahad, M. T., Li, Y., Song, B., & Bhuiyan, T. (2023). Comparison of CNN-based deep learning architectures for rice diseases classification. *Artificial Intelligence in Agriculture*, 9, 22–35. <https://doi.org/10.1016/J.AIIA.2023.07.001>
- Anaya-Isaza, A., Mera-Jiménez, L., & Zequera-Diaz, M. (2021). An overview of deep learning in medical imaging. *Informatics in Medicine Unlocked*, 26, 100723. <https://doi.org/10.1016/J.IMU.2021.100723>
- Faturrahman, R., Hariyani, Y. S., & Hadiyoso, S. (2023). Klasifikasi Jajanan Tradisional Indonesia berbasis Deep Learning dan Metode Transfer Learning. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 11(4), 945. <https://doi.org/10.26760/elkomika.v11i4.945>
- Jerandu, C. Y., Batarius, P., Aristo, A., & Sinlae, J. (2022). Identifikasi Kualitas Kesegaran Ikan Menggunakan Algoritma K-Nearest Neighbor Berdasarkan Ekstraksi Ciri Warna Hue, Saturation, dan Value (HSV). *Technology and Science (BITS)*, 4(3). <https://doi.org/10.47065/bits.v4i3.2613>
- Kassania, S. H., Kassanib, P. H., Wesolowskic, M. J., Schneidera, K. A., & Detersa, R. (2021). Automatic Detection of Coronavirus Disease (COVID-19) in X-ray and CT Images: A Machine Learning Based Approach. *Biocybernetics and Biomedical Engineering*, 41(3), 867–879. <https://doi.org/10.1016/J.BBE.2021.05.013>
- Lestari, N., Yuwana, Y., & Efendi, Z. (2015). LEVELS OF FRESHNESS AND PHYSICAL DAMAGE IDENTIFICATION OF FISH AVAILABLE FOR COMSUMERS AT PASAR MINGGU MARKET BENGKULU. *Jurnal Agroindustri*, 5(1), 44–56. <https://doi.org/10.31186/J.AGROIND.5.1.44-56>
- Mouton, C., Myburgh, J. C., & Davel, M. H. (2020). Stride and Translation Invariance in CNNs. In *Communications in Computer and Information Science* (Vol. 1342, pp. 267–281). Springer Science and Business Media Deutschland GmbH. https://doi.org/10.1007/978-3-030-66151-9_17
- Prasetyo, E., Purbaningtyas, R., Dimas Adityo, R., Prabowo, E. T., Ferdiansyah, A. I., & Korespondensi, P. (2021). Perbandingan Convolution Neural Network Untuk Klasifikasi Kesegaran Ikan Bandeng Pada Citra Mata. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 8(3), 601–608. <https://doi.org/10.25126/JTIHK.2021834369>
- Sholihin, M., & Rosidi Zamroni, M. (2021). Identifikasi Kesegaran Ikan Berdasarkan Citra Insang dengan Metode Convolution Neural Network. *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 8(3), 1352–1360. <https://doi.org/10.35957/JATISI.V8I3.939>
- Sitaula, C., & Hossain, M. B. (2021). Attention-based VGG-16 model for COVID-19 chest X-ray image classification. *Applied Intelligence*, 51(5), 2850–2863. <https://doi.org/10.1007/s10489-020-02055-x>
- Thakur, T., Batra, I., Malik, A., Ghimire, D., Kim, S. H., & Sanwar Hosen, A. S. M. (2023). RNN-CNN Based Cancer Prediction Model for Gene Expression. *IEEE Access*, 11. <https://doi.org/10.1109/ACCESS.2023.3332479>
- Wang, H. nan, Liu, N., Zhang, Y. yun, Feng, D. wei, Huang, F., Li, D. sheng, & Zhang, Y. ming. (2020). Deep reinforcement learning: a survey. *Frontiers of Information Technology and Electronic Engineering*, 21(12), 1726–1744. <https://doi.org/10.1631/FITEE.1900533>
- Zegarra, F. C., Vargas-Machuca, J., & Coronado, A. M. (2021). Comparison of CNN and CNN-LSTM Architectures for Tool Wear Estimation. *Proceedings of the 2021 IEEE Engineering International Research Conference, EIRCON 2021*. <https://doi.org/10.1109/EIRCON52903.2021.9613659>