



Model Convolutional Neural Network (CNN) Custom Sequential untuk Klasifikasi Citra Ikan Hias Carassius Auratus pada Industri Akuakultur

Rodiah^{1*}, Diana Tri Susetianingtias², Eka Patriya³

¹Program Studi Informatika, Universitas Gunadarma, Depok, Indonesia

² Program Studi Sistem Komputer, Universitas Gunadarma, Depok, Indonesia

³ Program Studi Manajemen, Universitas Gunadarma, Depok, Indonesia

Artikel Info

Kata Kunci:

Akuakultur;
Carassius auratus;
CNN;
Custom Sequential;
Ikan Hias.

Keywords:

Aquaculture;
Carassius auratus;
CNN;
Custom Sequential;
Ornamental Fish.

Riwayat Artikel:

Submitted: 05 Juli 2025

Accepted: 18 September 2025

Published: 18 September 2025

Abstrak: Identifikasi varietas ikan hias Carassius auratus dengan keanekaragaman morfologi yang tinggi masih sering dilakukan secara manual, sehingga menimbulkan kesulitan bagi para pecinta ikan hias maupun pelaku akuakultur dalam membedakan jenisnya secara tepat. Kondisi ini menuntut adanya solusi berbasis teknologi yang mampu memberikan hasil identifikasi lebih cepat, praktis, dan presisi. Penelitian ini bertujuan untuk mengembangkan model klasifikasi citra menggunakan pendekatan Convolutional Neural Network (CNN) dengan arsitektur custom sequential sebagai sistem identifikasi visual otomatis. Tahapan penelitian dilakukan melalui pengumpulan 2.080 citra ikan yang mewakili delapan kelas varietas, dilanjutkan dengan proses pra-pemrosesan data agar citra siap digunakan pada tahap pelatihan model. Arsitektur CNN yang dibangun terdiri dari tujuh lapisan konvolusi dengan jumlah filter bertingkat mulai dari 32 hingga 256, disertai proses pooling, aktivasi ReLU, transformasi flatten, serta lapisan fully connected dengan mekanisme dropout untuk mengurangi overfitting, dan diakhiri dengan fungsi aktivasi softmax sebagai klasifikasi multi-kelas. Hasil eksperimen menunjukkan bahwa model mampu mengklasifikasikan citra ikan hias dengan tingkat akurasi mencapai 93,03% serta menghasilkan prediksi data uji secara konsisten tepat. Penelitian ini berkontribusi dalam menghadirkan pendekatan klasifikasi berbasis citra yang efisien, akurat, dan aplikatif, sehingga dapat mendukung proses identifikasi varietas ikan hias dalam industri akuakultur secara lebih modern dan berbasis teknologi.

Abstract: The identification of ornamental fish varieties, particularly Carassius auratus with its high morphological diversity, is still often carried out manually, creating difficulties for ornamental fish enthusiasts as well as aquaculture practitioners in distinguishing species accurately. This condition requires a technology-based solution that is able to provide faster, practical, and precise identification results. This study aims to develop an image classification model using a Convolutional Neural Network (CNN) approach with a custom sequential architecture as an automatic visual identification system. The research stages were conducted by collecting 2,080 fish images representing eight variety classes, followed by data preprocessing to prepare the images for the model training stage. The CNN architecture was designed with seven convolutional layers consisting of progressively increasing filters ranging from 32 to 256, accompanied by pooling processes, ReLU activation, flatten transformation, and fully connected layers with dropout mechanisms to reduce overfitting, and finalized with a softmax activation function for multi-class classification.

The experimental results show that the model is capable of classifying ornamental fish images with an accuracy rate of 93.03% and producing consistently accurate predictions on test data. This study contributes by providing an efficient, accurate, and applicable image-based classification approach, which supports the identification of ornamental fish varieties in the aquaculture industry in a more modern and technology-driven manner.

Corresponding Author:

Rodiah

Email: diah.mcfdz@gmail.com

PENDAHULUAN

Ikan hias *Carassius auratus* dikenal sebagai salah satu spesies yang paling diminati dalam dunia akuakultur (Maia et al., 2025) dan perdagangan ikan hias. Kepopuleran spesies ini didukung oleh keberagaman varietasnya yang memiliki bentuk tubuh dan warna yang sangat variatif (Hu & Lima, 2024). Namun, keberagaman ini justru menimbulkan tantangan tersendiri, terutama dalam proses identifikasi visual. Baik pecinta ikan hias maupun pelaku industri akuakultur kerap mengalami kesulitan dalam membedakan tiap varietas secara tepat (Biondo & Burki, 2020). Kesalahan dalam mengidentifikasi jenis ikan tidak hanya berimplikasi pada aspek estetika (Tarihoran et al., 2024), tetapi juga dapat memengaruhi efektivitas budidaya, strategi pemasaran, hingga nilai jual di pasar. Mengingat pentingnya akurasi dalam proses tersebut, dibutuhkan sistem klasifikasi berbasis teknologi visual yang mampu memberikan hasil yang efisien dan konsisten. Beberapa pendekatan berbasis citra digital dan pembelajaran mesin telah dikembangkan dalam berbagai studi sebelumnya untuk menjawab permasalahan serupa.

Penelitian (Multajam et al., 2024) memanfaatkan kecerdasan buatan dalam bidang akuakultur dengan mengembangkan model klasifikasi untuk menentukan indukan awal (*early breeder*) pada ikan hias *Carassius auratus*. Penelitian ini menggunakan tiga pendekatan jaringan saraf tiruan, yaitu Learning Vector Quantization Neural Network (LVQNN), Probabilistic Neural Network (PNN), dan Pattern Recognition Neural Network (PRNN). Ketiganya diuji pada dataset berisi 120 sampel ikan dengan tujuh parameter input morfometrik seperti berat hidup, panjang tubuh, dan tinggi kepala. Hasil analisis menunjukkan bahwa ketiga model ANN memiliki kemampuan klasifikasi yang cukup baik, namun PRNN menunjukkan performa paling unggul dalam hal akurasi, presisi, dan sensitivitas. Penelitian dalam mengidentifikasi tiga spesies ikan hias *Carassius auratus*, yaitu: Fantail, Oranda, dan Ranchu dilakukan (Aristoteles et al., 2021) dengan pendekatan pengenalan pola berbasis kecerdasan buatan. Metode yang digunakan mencakup proses ekstraksi ciri menggunakan *Gabor filter* dan klasifikasi menggunakan PNN. *Gabor filter* digunakan untuk mengekstraksi fitur tekstur dari citra ikan berdasarkan parameter seperti frekuensi, orientasi, dan ukuran kernel, yang kemudian menghasilkan vektor fitur untuk proses klasifikasi. Hasil penelitian menunjukkan bahwa kombinasi parameter kernel size 5x5, frekuensi 3, dan orientasi 5 mampu menghasilkan akurasi hingga 100%.

Penelitian (Moralista & Rueda, 2023) mengusulkan model klasifikasi dan deteksi penyakit ikan pada sistem akuakultur menggunakan pendekatan *deep learning* berbasis CNN yang dikustomisasi dengan arsitektur ResNet-50. Studi ini difokuskan pada tiga jenis ikan ekonomis penting dalam akuakultur India, yaitu Mrigala, Catla, dan Rohu. Model dikembangkan untuk mengklasifikasikan spesies ikan sekaligus mendeteksi jenis penyakit yang diderita, mengingat infeksi pada ikan, baik akibat patogen alami maupun polutan lingkungan yang merupakan tantangan utama dalam budidaya. Hasil evaluasi menunjukkan bahwa ResNet-50 memiliki kinerja klasifikasi yang sangat baik dalam membedakan ketiga spesies ikan dan kondisi kesehatannya. Penelitian (Haddad & Mohammed, 2024) mengembangkan sistem deteksi dan klasifikasi penyakit ikan berbasis *deep learning*, khususnya menggunakan arsitektur *Convolutional Neural Networks* (CNN), untuk meningkatkan akurasi diagnosis penyakit pada budidaya ikan. Model CNN dirancang menggunakan pendekatan berlapis dengan aktivasi ReLU dan *pooling*, serta dilatih menggunakan Keras *Sequential API*. Hasil eksperimen menunjukkan akurasi tinggi dalam mendeteksi berbagai penyakit ikan secara otomatis, didukung oleh

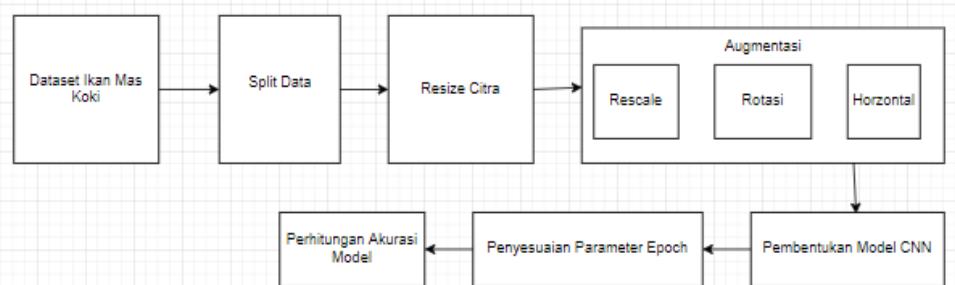
nilai *precision* dan *recall* yang seimbang. Penelitian ini juga menyoroti urgensi sistem pemantauan penyakit yang efisien di tengah ancaman perubahan iklim terhadap kesehatan ikan, serta pentingnya penerapan teknologi seperti *Big Data*, IoT, dan robotika dalam pengelolaan perikanan yang berkelanjutan.

Studi-studi sebelumnya dalam klasifikasi ikan hias air tawar, khususnya spesies *Carassius auratus*, umumnya berfokus pada aspek terbatas. Multajam et al. (2024) hanya mengeksplorasi klasifikasi berdasarkan parameter morfometrik menggunakan jaringan saraf tiruan, sementara Aristoteles et al. (2021) memanfaatkan pendekatan berbasis fitur tekstur (Gabor filter) untuk mengenali tiga varietas. Di sisi lain, penelitian berbasis *deep learning* seperti yang dilakukan oleh Moralista & Rueda (2023) serta Haddad & Mohammed (2024) lebih menitikberatkan pada klasifikasi spesies ikan konsumsi dan deteksi penyakit, bukan pada varietas ornamental. Belum ada penelitian yang secara menyeluruh menerapkan proses scraping mandiri, augmentasi citra lengkap, dan pelatihan CNN dari awal untuk mengklasifikasikan berbagai varietas ikan hias jenis *goldfish* secara visual. Hal ini menunjukkan adanya celah penelitian dalam pengembangan sistem klasifikasi otomatis berbasis visual untuk spesies ornamental dengan karakteristik morfologi yang sangat mirip.

Penelitian ini mengusulkan pendekatan melalui pengembangan *Model Convolutional Neural Network (CNN) Custom Sequential* untuk klasifikasi citra ikan hias *Carassius auratus* dalam mendukung kebutuhan industri akuakultur. Penelitian ini memanfaatkan dataset delapan varietas *goldfish* dengan total 2080 citra. Seluruh gambar diproses melalui *pipeline preprocessing* komprehensif, termasuk *resize*, augmentasi (*rescale*, rotasi, *horizontal flip*), dan pembagian data latih dan validasi. Model CNN yang dikembangkan terdiri dari tujuh lapisan konvolusi dengan kombinasi filter 32 sampai 256, *pooling layer*, *flatten*, *dense*, *dropout*, serta fungsi aktivasi ReLU dan *Softmax*. Kontribusi utama dari studi ini terletak pada rancangan arsitektur CNN yang dibangun dari awal (*custom sequential*) dan disesuaikan secara spesifik untuk kebutuhan klasifikasi multikategori ikan hias dengan tingkat akurasi tinggi, yang dapat digunakan sebagai dasar sistem identifikasi otomatis dalam industri budidaya ikan hias berbasis citra digital.

METODE

Pada penelitian ini, diimplementasikan penggunaan Model CNN Custom Sequential dalam melakukan Klasifikasi citra ikan hias *Carassius auratus* seperti dapat dilihat pada Gambar 1.



Gambar 1. Metode Penelitian Klasifikasi Citra Ikan Hias *Carassius auratus*

Gambar 1. menggambarkan alur metodologi yang digunakan dalam penelitian ini untuk melakukan klasifikasi citra ikan hias *Carassius auratus*. Proses dimulai dengan tahap scraping data dari sumber daring untuk memperoleh dataset citra ikan hias. Selanjutnya, dilakukan pembagian dataset menjadi data latih dan data validasi (data splitting). Tahap berikutnya adalah praproses citra yang mencakup resize untuk menyeragamkan ukuran gambar dan augmentasi data guna memperluas variasi data pelatihan. Proses augmentasi mencakup transformasi rescaling, rotasi, dan horizontal flipping. Setelah data siap, model CNN disusun dengan pendekatan custom sequential. Model kemudian dilatih melalui penyesuaian parameter epoch dan diakhiri dengan evaluasi kinerja menggunakan metrik akurasi dan loss function, yang ditampilkan untuk menilai performa klasifikasi terhadap dataset yang digunakan.

Dataset Ikan Hias *Carassius Auratus*

Dataset pada penelitian ini menggunakan dataset Ikan hias *Carassius Auratus* dengan melakukan scraping terhadap google image sejumlah 2080 citra, kemudian dilakukan labelling secara manual didapatkan 8 kelas jenis Ikan hias *Carassius Auratus* dengan rincian seperti dapat dilihat pada Tabel 1.

Tabel 1. Citra Ikan hias *Carassius Auratus*

No	Citra	Jenis	Jumlah Dataset
1		Oranda	260
2		Ryukin	260
3		Choton	260
4		Bubble Eye	260
5		Ranchu	260
6		Pearl Scale	260
7		Telescope Eye	260
8		Butterfly Tail	260
TOTAL CITRA			2080

Split Dataset Ikan hias *Carassius Auratus*

Pada tahap pembagian dataset (split dataset), citra ikan hias *Carassius auratus* dibagi menjadi dua kategori utama, yaitu data latih dan data validasi, dengan rasio 80% untuk pelatihan dan 20% untuk validasi (Cermakova et al., 2023). Total dataset yang digunakan berjumlah 2080 citra, terdiri dari delapan kelas jenis ikan hias, yakni Oranda, Ryukin, Ranchu, Pearl Scale, Telescope Eye, Bubble Eye, Butterfly Tail, dan Choton. Masing-masing kelas terdiri atas 260 citra, yang kemudian dibagi menjadi 208 citra untuk data latih dan 52 citra untuk data validasi. Pembagian ini bertujuan agar model CNN dapat belajar secara optimal dari variasi data yang representatif serta diuji kemampuannya secara akurat pada data yang belum pernah dilihat sebelumnya.

Resize Citra

Proses resize citra dilakukan untuk menyesuaikan ukuran citra agar kompatibel dengan arsitektur jaringan saraf tiruan yang akan dibangun, serta untuk menyeragamkan dimensi seluruh citra dan mengurangi beban komputasi pada tahap pelatihan model. Contoh proses resize ditampilkan pada Gambar 2.



Gambar 2. Contoh Proses Resize Citra

Dalam penelitian ini, citra ikan hias Carassius auratus yang semula berukuran 1300 x 1058 piksel diubah ukurannya menjadi 150 x 150 piksel. Penyesuaian ini penting agar citra dapat diolah secara efisien oleh model CNN tanpa kehilangan informasi visual yang esensial(Wojciuk et al., 2024). Jumlah total citra yang digunakan sebanyak 2.080 gambar, terbagi secara seimbang ke dalam delapan kelas jenis ikan hias, masing-masing terdiri dari 260 citra berformat .jpg.

Augmentasi data

Tahapan augmentasi data dalam penelitian ini merupakan strategi penting untuk meningkatkan generalisasi model dengan memperkaya variasi citra yang tersedia tanpa perlu menambah jumlah data asli (Shorten & Khoshgoftaar, 2019). Augmentasi data dilakukan dengan cara memodifikasi citra sedemikian rupa sehingga secara visual tetap dikenali oleh manusia sebagai gambar yang sama, tetapi dianggap berbeda oleh model pembelajaran mesin. Tujuannya adalah untuk meningkatkan keragaman distribusi data latih, meminimalkan overfitting, dan memperkuat kemampuan model dalam mengenali objek dari berbagai kondisi visual (Mol & Jose, 2024). Terdapat tiga teknik augmentasi utama yang diterapkan pada penelitian ini, yaitu:

1. Rescale

Berfungsi untuk melakukan normalisasi intensitas piksel dengan mengubah nilai RGB dari rentang [0, 255] ke rentang [0.0, 1.0]. Secara matematis, proses ini dapat dinyatakan dengan Persamaan:

$$I' = \frac{I}{255} \quad (1)$$

I adalah nilai piksel asli dan I' adalah nilai piksel setelah normalisasi. Proses ini penting untuk mempercepat konvergensi saat pelatihan model untuk mengurangi penyebaran nilai-nilai piksel dalam data citra sebelum dinormalisasi (Suhana et al., 2022). Citra digital biasanya memiliki nilai piksel dalam rentang 0 hingga 255 (untuk gambar RGB 8 bit). Rentang nilai yang besar seperti ini dapat mengakibatkan gradien selama proses training jadi tidak stabil, proses pembelajaran lebih lambat, dan model berpotensi kesulitan mencapai minimum loss yang optimal (konvergensi).

2. Rotasi Acak

Yaitu proses transformasi dengan memutar citra terhadap pusatnya sebesar sudut tertentu yang dipilih secara acak dalam rentang tertentu (misalnya $\pm 40^\circ$)(D. Li et al., 2022). Secara matematis, rotasi dapat digambarkan dengan matriks transformasi rotasi dua dimensi menggunakan Persamaan :

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} \quad (2)$$

(x,y) adalah koordinat piksel sebelum rotasi dan (x',y') setelah rotasi dengan sudut θ .

3. Flip Horizontal

Yaitu pembalikan citra sepanjang sumbu vertikal. Operasi ini secara matematis dapat diwakili oleh transformasi refleksi dengan matriks $\begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix}$ yang mengubah posisi piksel (x,y) menjadi (-x,y), sehingga menciptakan efek cermin secara horizontal(Ahmed et al., 2022).

Ketiga teknik augmentasi tersebut dikombinasikan dan diterapkan secara acak pada seluruh dataset sebelum proses pelatihan CNN. Hal ini membantu model belajar dari berbagai kondisi tampilan visual yang mungkin terjadi pada data di dunia nyata, sehingga meningkatkan akurasi dan ketangguhan sistem klasifikasi terhadap noise visual maupun perbedaan sudut pandang.

Pembentukan model CNN Custom sequential

Pada tahap pembentukan model, penelitian ini menggunakan arsitektur Convolutional Neural Network (CNN) berbasis model Sequential dari Keras. Arsitektur ini terdiri dari tiga komponen utama, yaitu input layer, feature extraction layer (yang meliputi lapisan konvolusi dan pooling), serta classification layer yang mencakup lapisan fully connected dan output layer. Model menerima input

berupa citra berukuran 150×150 piksel dengan 3 kanal warna (RGB). Proses awal dimulai dengan tujuh lapisan konvolusi dan pooling yang dirancang secara bertingkat, masing-masing dengan konfigurasi sebagai berikut: satu lapisan dengan 32 filter, dua lapisan dengan 64 filter, dua lapisan dengan 128 filter, dan dua lapisan dengan 256 filter. Setiap lapisan konvolusi menggunakan fungsi aktivasi ReLU, diikuti oleh operasi max pooling untuk mereduksi dimensi spasial dan memperkuat fitur dominan. Hasil dari tahap ekstraksi fitur kemudian diproses melalui lapisan flatten untuk mengubah matriks fitur menjadi vektor satu dimensi, yang selanjutnya digunakan sebagai input untuk lapisan fully connected (dense layer). Lapisan dropout diterapkan guna mengurangi risiko overfitting dengan menonaktifkan sebagian neuron secara acak selama pelatihan(Salehin & Kang, 2023). Proses klasifikasi akhir dilakukan melalui fungsi aktivasi softmax, yang menghasilkan probabilitas untuk setiap kelas target sehingga model dapat menentukan jenis ikan hias dengan tepat. Arsitektur model CNN Custom sequential dapat dilihat pada Gambar 3.

Layer (type)	Output Shape	Param #
<hr/>		
conv2d (Conv2D)	(None, 150, 150, 32)	2432
max_pooling2d (MaxPooling2D)	(None, 75, 75, 32)	0
)		
conv2d_1 (Conv2D)	(None, 75, 75, 64)	51264
conv2d_2 (Conv2D)	(None, 75, 75, 64)	36928
max_pooling2d_1 (MaxPooling2D)	(None, 37, 37, 64)	0
dropout (Dropout)	(None, 37, 37, 64)	0
conv2d_3 (Conv2D)	(None, 37, 37, 128)	73856
conv2d_4 (Conv2D)	(None, 37, 37, 128)	147584
max_pooling2d_2 (MaxPooling2D)	(None, 18, 18, 128)	0
dropout_1 (Dropout)	(None, 18, 18, 128)	0
conv2d_5 (Conv2D)	(None, 18, 18, 256)	295168
conv2d_6 (Conv2D)	(None, 18, 18, 256)	590080
max_pooling2d_3 (MaxPooling2D)	(None, 9, 9, 256)	0
dropout_2 (Dropout)	(None, 9, 9, 256)	0
flatten (Flatten)	(None, 20736)	0
dense (Dense)	(None, 512)	10617344
dropout_3 (Dropout)	(None, 512)	0
dense_1 (Dense)	(None, 8)	4104
<hr/>		
Total params:	11,818,760	
Trainable params:	11,818,760	
Non-trainable params:	0	

Gambar 3. Arsitektur CNN Custom Sequential

Arsitektur model Convolutional Neural Network (CNN) yang digunakan dalam penelitian ini terdiri atas sejumlah lapisan konvolusi, flatten, dan fully connected layer (dense), yang masing-masing menghasilkan sejumlah parameter (Rodiah et al., 2024). Perhitungan jumlah parameter pada setiap lapisan mengikuti Persamaan :

$$\text{Parameter} = (n + m + k + 1) \times L \quad (3)$$

Variabel n adalah lebar filter, m adalah tinggi filter, k adalah jumlah peta fitur (feature maps) input, dan L adalah jumlah peta fitur output (jumlah filter/lapisan). Simbol +1 merepresentasikan bias yang ditambahkan pada setiap output unit. Berdasarkan arsitektur yang digunakan pada Gambar 3, jumlah parameter yang dihasilkan pada lapisan conv2d pertama adalah 2.432 dengan konfigurasi filter berukuran 5×5 , 3 saluran warna (RGB), dan 32 filter output. Pada lapisan conv2d_1, jumlah parameter meningkat menjadi 51.264 karena adanya 64 filter dan 32 input feature map. Selanjutnya, conv2d_2 menghasilkan 36.928 parameter dengan filter 3×3 dan 64 saluran input. Lapisan conv2d_3 dan conv2d_4 memiliki output feature map sebanyak 128, masing-masing menghasilkan 73.856 dan 147.584 parameter.

Jumlah parameter dalam arsitektur CNN yang digunakan dalam penelitian ini menunjukkan peningkatan signifikan pada lapisan-lapisan akhir, khususnya pada conv2d_5 dan conv2d_6 yang masing-masing menghasilkan 295.168 dan 590.080 parameter dengan 256 peta fitur keluaran. Setelah proses konvolusi selesai, fitur dua dimensi yang dihasilkan diubah menjadi vektor satu dimensi melalui proses flatten, menghasilkan 20.736 unit berdasarkan dimensi spasial akhir sebesar $9 \times 9 \times 256$. Vektor ini kemudian menjadi input pada lapisan dense pertama dengan 512 unit neuron, yang menghasilkan 10.617.344 parameter. Selanjutnya, lapisan dense kedua yang bertanggung jawab dalam klasifikasi delapan kelas menghasilkan 4.104 parameter. Secara keseluruhan, total parameter dari seluruh arsitektur model mencapai 11.674.496, yang terdiri dari tujuh lapisan konvolusi (1.195.312 parameter), satu lapisan flatten (20.736 parameter), dan dua lapisan fully connected (10.617.344 dan 4.104 parameter).

Besarnya jumlah parameter ini menunjukkan kapasitas representasi model yang tinggi, yang secara teoritis mampu menangkap kompleksitas pola visual dalam citra ikan hias Carassius auratus. Namun demikian, tingginya kompleksitas arsitektur ini juga membawa tantangan dari sisi komputasi dan risiko overfitting, terutama karena jumlah data terbatas(Zhu, 2024). Oleh karena itu, strategi regularisasi seperti dropout, augmentasi data, dan early stopping diterapkan untuk memastikan model tetap generalis dan tidak sekadar menghafal data pelatihan(Liu et al., 2023). Melalui pengaturan parameter pelatihan yang tepat dan optimalisasi sumber daya komputasi, model CNN ini diharapkan mampu mencapai konvergensi yang efisien serta performa klasifikasi yang andal.

Penyesuaian Parameter Epoch

Selanjutnya, untuk memastikan proses pelatihan model berlangsung secara efisien dan tidak berlarut-larut, dilakukan penyesuaian terhadap parameter pelatihan, khususnya jumlah epoch dan penggunaan mekanisme callbacks seperti dapat dilihat pada Pseudocode berikut :

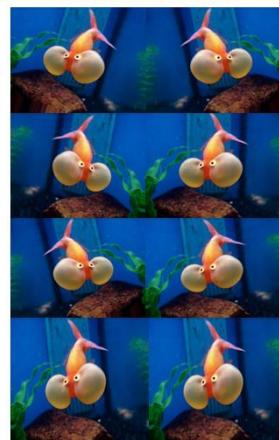
```
hist=model.fit(
    train_generator,
    steps_per_epoch=50,
    epochs=300,
    validation_data=validation_generator,
    callbacks=[checkpoint, myCallBack],
    verbose=1)
```

Pelatihan model dilakukan dengan konfigurasi 50 steps per epoch dan total maksimum 300 epochs. Jumlah epoch yang besar dipilih untuk memberikan kesempatan bagi model dalam mencapai konvergensi optimal. Salah satu strategi yang digunakan untuk mencegah pelatihan yang berlebihan (overtraining), digunakan callback function berupa early stopping yang akan secara otomatis menghentikan proses pelatihan ketika akurasi validasi telah mencapai nilai maksimum atau tidak mengalami peningkatan signifikan dalam beberapa epoch terakhir(H. Li et al., 2024). Strategi ini sekaligus berperan dalam menjaga generalisasi model dan mengurangi risiko overfitting akibat kompleksitas parameter yang tinggi.

HASIL DAN PEMBAHASAN

Hasil implementasi dan evaluasi model CNN Custom Sequential yang dikembangkan digunakan untuk mengklasifikasikan delapan jenis ikan hias Carassius auratus. Proses analisis dilakukan berdasarkan tahapan preprocessing, pelatihan model, serta evaluasi akurasi dan performa klasifikasi menggunakan metrik yang relevan. Setiap hasil yang diperoleh dianalisis secara komprehensif untuk mengidentifikasi efektivitas pendekatan yang digunakan serta membandingkannya dengan temuan sebelumnya yang relevan di bidang klasifikasi citra ikan dalam konteks akuakultur.

Tahapan awal yang dianalisis adalah proses augmentasi citra, yang memainkan peran penting dalam memperkaya keragaman data latih dan mengurangi risiko overfitting akibat keterbatasan jumlah dataset. Hasil augmentasi pada penelitian ini dapat dilihat pada Gambar 4.



Gambar 4. Hasil Augmentasi Citra Carassius Auratus

Augmentasi pada penelitian dilakukan dengan menerapkan tiga teknik utama, yaitu rescaling, rotation, dan horizontal flipping. Proses rescaling dilakukan dengan normalisasi nilai piksel citra dari rentang 0–255 menjadi 0–1 menggunakan skala 1/255, sehingga mempercepat konvergensi model selama pelatihan. Teknik rotation menghasilkan variasi arah orientasi ikan, sedangkan horizontal flipping menciptakan variasi spasial terhadap simetri gambar. Kombinasi ketiga metode ini diaplikasikan secara acak terhadap seluruh citra latih, menghasilkan data sintetis yang tetap merepresentasikan objek asli namun memiliki distribusi yang lebih bervariasi secara visual. Hasil augmentasi menunjukkan peningkatan keragaman citra yang signifikan, yang kemudian berdampak pada kestabilan proses pelatihan dan kemampuan generalisasi model. Selanjutnya, proses pelatihan model dilakukan selama 300 epoch dengan konfigurasi step per epoch sebanyak 50 langkah. Berdasarkan hasil training yang ditampilkan pada Gambar 5.

```

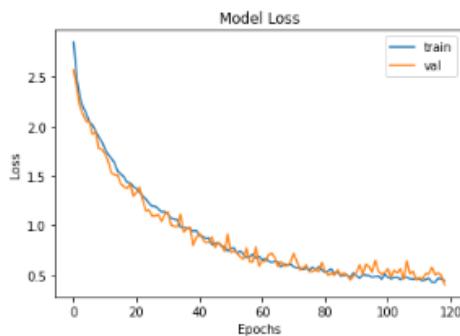
Epoch 116/300
50/50 [=====] - ETA: 0s - loss: 0.4843 - accuracy: 0.8894
Epoch 00116: val_loss did not improve from 0.39992
50/50 [=====] - 30s 619ms/step - loss: 0.4843 - accuracy: 0.8894 - val_loss: 0.5179 - val_accuracy: 0.9135
Epoch 117/300
50/50 [=====] - ETA: 0s - loss: 0.4822 - accuracy: 0.8863
Epoch 00117: val_loss did not improve from 0.39992
50/50 [=====] - 30s 604ms/step - loss: 0.4822 - accuracy: 0.8863 - val_loss: 0.4253 - val_accuracy: 0.9231
Epoch 118/300
50/50 [=====] - ETA: 0s - loss: 0.4553 - accuracy: 0.9000
Epoch 00118: val_loss did not improve from 0.39992
50/50 [=====] - 31s 619ms/step - loss: 0.4553 - accuracy: 0.9000 - val_loss: 0.5205 - val_accuracy: 0.9111
Epoch 119/300
50/50 [=====] - ETA: 0s - loss: 0.4714 - accuracy: 0.8906
Epoch 00119: val_loss did not improve from 0.39992
50/50 [=====] - 30s 619ms/step - loss: 0.4714 - accuracy: 0.8906 - val_loss: 0.4595 - val_accuracy: 0.9207
Epoch 120/300
50/50 [=====] - ETA: 0s - loss: 0.4587 - accuracy: 0.8958
Epoch 00120: val_loss improved from 0.39992 to 0.38279, saving model to /content/drive/MyDrive/Dataset/goldfish_weight/model.h5
50/50 [=====] - 31s 619ms/step - loss: 0.4587 - accuracy: 0.8958 - val_loss: 0.3828 - val_accuracy: 0.9207
Epoch 121/300
50/50 [=====] - ETA: 0s - loss: 0.4398 - accuracy: 0.8863
Epoch 00121: val_loss did not improve from 0.38279
50/50 [=====] - 31s 619ms/step - loss: 0.4398 - accuracy: 0.8863 - val_loss: 0.4627 - val_accuracy: 0.9087
Epoch 122/300
50/50 [=====] - ETA: 0s - loss: 0.4519 - accuracy: 0.8944
Epoch 00122: val_loss did not improve from 0.38279
50/50 [=====] - 30s 619ms/step - loss: 0.4519 - accuracy: 0.8944 - val_loss: 0.4063 - val_accuracy: 0.9255
Epoch 123/300
50/50 [=====] - ETA: 0s - loss: 0.4418 - accuracy: 0.9038
Epoch 00123: val_loss did not improve from 0.38279
50/50 [=====] - 30s 619ms/step - loss: 0.4418 - accuracy: 0.9038 - val_loss: 0.4518 - val_accuracy: 0.9038
Epoch 124/300
50/50 [=====] - ETA: 0s - loss: 0.4683 - accuracy: 0.8938
Epoch 00124: val_loss did not improve from 0.38279
Akurasi validasi telah mencapai > 93%
50/50 [=====] - 30s 609ms/step - loss: 0.4683 - accuracy: 0.8938 - val_loss: 0.4116 - val_accuracy: 0.9303

```

Gambar 5. Hasil Training dengan Penyesuaian Nilai Epoch

Gambar 5 menunjukkan model menunjukkan performa yang sangat baik, ditandai dengan nilai loss akhir sebesar 0.4683 dan akurasi sebesar 0.9303 atau setara dengan 93,03%. Nilai ini mencerminkan bahwa model mampu melakukan klasifikasi delapan jenis ikan hias *Carassius auratus* dengan tingkat ketepatan yang tinggi. Rata-rata waktu pelatihan per epoch tercatat sekitar 30 detik, yang menunjukkan efisiensi pelatihan pada arsitektur model yang telah dirancang. Dalam proses training, digunakan mekanisme callbacks berupa early stopping, yang bertujuan untuk menghentikan pelatihan secara otomatis ketika akurasi yang diinginkan telah tercapai, guna menghindari overfitting dan efisiensi waktu komputasi. Gambar 5 juga menunjukkan tren yang konsisten antara akurasi pelatihan dan validasi, serta nilai loss yang menurun secara stabil. Ini mengindikasikan bahwa model tidak hanya belajar dengan baik dari data latih, tetapi juga memiliki kemampuan generalisasi yang baik terhadap

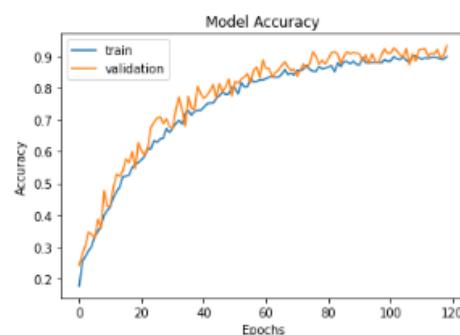
data validasi. Keberhasilan mencapai akurasi di atas 90% juga mencerminkan efektivitas dari proses augmentasi dan arsitektur CNN yang digunakan, di mana kombinasi konvolusi bertingkat, fungsi aktivasi ReLU, dan regularisasi dropout memberikan kontribusi signifikan terhadap performa model secara keseluruhan. Visualisasi performa model dilakukan melalui dua metrik utama, yaitu loss dan accuracy, yang direpresentasikan dalam bentuk grafik. Gambar 6 merupakan visualisasi grafik loss.



Gambar 6. Visualisasi Grafik Loss Model Klasifikasi Carassius Auratus

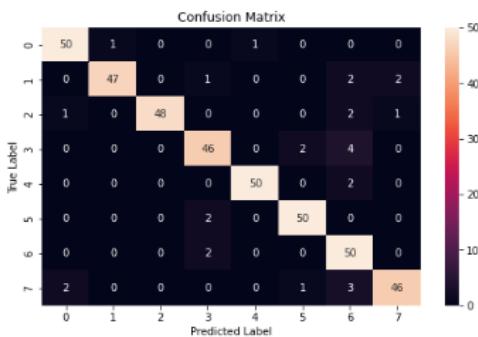
Grafik Gambar 6 menunjukkan perubahan nilai loss selama proses pelatihan dan validasi. Model yang baik ditandai dengan menurunnya nilai loss secara konsisten pada kedua grafik, serta tidak adanya jarak yang signifikan antara training loss dan validation loss. Dalam penelitian ini, grafik menunjukkan bahwa model mampu mempelajari pola data dengan stabil, tanpa mengalami gejala overfitting yang serius, karena loss pada data validasi tetap berada dalam tren yang searah dengan loss data pelatihan.

Selanjutnya, Gambar 7 menunjukkan hasil visualisasi akurasi model selama proses pelatihan. Grafik ini memperlihatkan bahwa kurva training accuracy dan validation accuracy meningkat secara progresif dan stabil, dengan jarak yang relatif kecil di antara keduanya. Hal ini mengindikasikan bahwa model tidak hanya memiliki performa pelatihan yang baik, tetapi juga mampu melakukan generalisasi terhadap data baru.



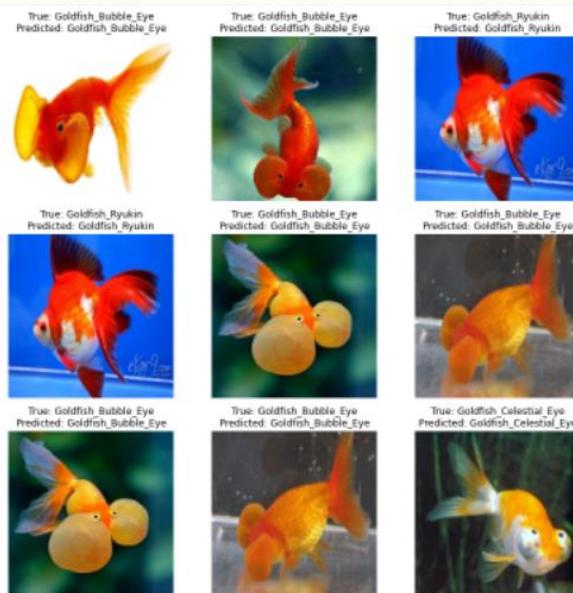
Gambar 7. Visualisasi Akurasi Model Klasifikasi Carassius Auratus

Evaluasi performa model juga dilakukan menggunakan confusion matrix untuk melihat distribusi prediksi benar dan salah pada setiap kelas ikan hias Carassius auratus seperti dapat dilihat pada Gambar 8.



Gambar 8. Confusion Matrix Model Klasifikasi Carassius Auratus

Berdasarkan 8, diketahui bahwa mayoritas kelas memiliki nilai true positive (TP) yang tinggi, seperti Oranda, Ryukin, dan Ranchu yang masing-masing memiliki 50 TP. Namun, beberapa kelas juga mengalami kesalahan prediksi, ditunjukkan dengan adanya false positive (FP) dan false negative (FN), seperti pada kelas Telescope Eye yang memiliki FN sebanyak 6 dan FP sebanyak 3. Fenomena ini mengindikasikan bahwa meskipun model secara umum bekerja dengan baik, masih terdapat tantangan dalam membedakan fitur visual antar kelas tertentu yang memiliki kemiripan bentuk atau warna. Kesalahan klasifikasi ini menjadi dasar penting untuk memahami batasan model serta area yang memerlukan peningkatan akurasi. Gambar 9, yang memperlihatkan bahwa sebagian besar prediksi model berhasil mengidentifikasi kelas target dengan tepat.



Gambar 9. Contoh Hasil Klasifikasi Carassius Auratus

Untuk memperkuat evaluasi model, dilakukan perhitungan metrik evaluasi lanjutan berupa precision, recall, dan f1-score menggunakan rumus matematis yang bergantung pada nilai TP, FP, dan FN. Hasil perhitungan menunjukkan bahwa kelas Celestial Eye memperoleh nilai precision sempurna sebesar 1, dengan recall sebesar 0.92 dan f1-score sebesar 0.96. Sementara itu, kelas Ryukin memiliki precision yang relatif rendah (0.79), meskipun recall-nya tinggi (0.96), sehingga menghasilkan f1-score sebesar 0.87. Hal ini mengindikasikan bahwa model cukup sensitif dalam mengenali kelas Ryukin, namun rentan terhadap kesalahan prediksi yang menghasilkan false positive. Sebaliknya, kelas Butterfly Tail menunjukkan precision tinggi (0.98) namun recall lebih rendah (0.90), yang mencerminkan bahwa meskipun model jarang salah mengklasifikasikan kelas lain sebagai Butterfly Tail, masih ada citra dari kelas ini yang tidak berhasil dikenali dengan tepat. Secara keseluruhan, nilai f1-score yang berkisar antara 0.87 hingga 0.97 menunjukkan performa model yang cukup solid dalam klasifikasi multi-kelas, dengan potensi peningkatan pada kelas-kelas yang memiliki

ketidakseimbangan visual antar fitur. Perbandingan kuantitatif dengan penelitian terdahulu dapat dilihat pada Tabel 2.

Tabel 2. Perbandingan Kuantitatif dengan Penelitian Terdahulu

Peneliti & Tahun	Objek Klasifikasi	Jumlah Data	Jumlah Kelas	Metode / Arsitektur	Akurasi %
Multajam et al., 2024	<i>Carassius auratus</i> (early breeder)	120 sampel	1 target (klasifikasi breeder)	LVQNN, PNN, PRNN	PRNN: 92,50
Aristoteles et al., 2021	3 varietas <i>Carassius auratus</i> (Fantail, Oranda, Ranchu)	300 citra	3	Gabor Filter + PNN	100
Moralista & Rueda, 2023	Ikan ekonomis (Mrigala, Catla, Rohu)	1.500 citra	3	CNN berbasis ResNet-50	95,60
Haddad & Mohammed, 2024	Ikan budidaya (deteksi penyakit)	2.000 citra	Multi-label	CNN Kustom (Keras Sequential API)	94,80
Penelitian ini (2025)	8 varietas <i>Carassius auratus</i> (Oranda, Ryukin, Ranchu, Pearl Scale, Telescope Eye, Bubble Eye, Butterfly Tail, Choton)	2.080 citra	8	CNN Custom Sequential + Augmentasi (rescale, rotasi, flip)	93,03

Tabel 2 menunjukkan bahwa penelitian-penelitian terdahulu umumnya masih terbatas pada aspek tertentu, baik dari segi jumlah data, jumlah kelas, maupun objek yang diteliti. Multajam et al. (2024) hanya menggunakan parameter morfometrik non-visual dengan sampel relatif kecil, sementara Aristoteles et al. (2021) memang berhasil mencapai akurasi sempurna, namun hanya mencakup tiga varietas goldfish sehingga belum mewakili keragaman penuh spesies *Carassius auratus*. Penelitian berbasis deep learning seperti Moralista & Rueda (2023) maupun Haddad & Mohammed (2024) lebih menekankan pada klasifikasi spesies ikan konsumsi serta deteksi penyakit, bukan pada identifikasi varietas ornamental. Penelitian ini menawarkan kebaruan dengan mengimplementasikan CNN Custom Sequential yang dibangun dari awal dan dipadukan dengan proses scraping data mandiri, augmentasi citra komprehensif (rescale, rotasi, horizontal flip), serta klasifikasi delapan varietas *Carassius auratus* secara simultan. Dengan akurasi mencapai 93,03%, penelitian ini menghadirkan kontribusi signifikan sebagai model klasifikasi visual multi-kategori yang dapat mendukung identifikasi otomatis dalam industri akuakultur ikan hias yang selama ini masih bergantung pada pengamatan manual yang rentan kesalahan.

KESIMPULAN

Hasil implementasi dan evaluasi model CNN berbasis arsitektur Custom Sequential menunjukkan bahwa model mampu mengklasifikasikan delapan jenis ikan hias *Carassius auratus* secara efektif, dengan akurasi akhir sebesar 93,03% dan nilai loss sebesar 0,4683 setelah pelatihan selama 300 epoch. Strategi augmentasi berbasis rescaling, rotation, dan horizontal flipping terbukti berhasil meningkatkan keragaman data latih dan mengurangi risiko overfitting, yang ditunjukkan oleh kesesuaian kurva loss dan akurasi antara data pelatihan dan validasi. Selain itu, visualisasi confusion matrix menunjukkan dominasi nilai true positive yang tinggi pada sebagian besar kelas, meskipun terdapat kelas dengan tingkat kesalahan prediksi relatif lebih tinggi seperti Telescope Eye dan Ryukin. Evaluasi lanjutan menggunakan metrik precision, recall, dan f1-score menghasilkan nilai f1 antara 0,87–0,97, yang menunjukkan stabilitas model dalam klasifikasi multi-kelas, meskipun masih terdapat ruang

untuk perbaikan pada kelas dengan fitur visual mirip. Model CNN yang dikembangkan memiliki performa yang baik dan relevan untuk diterapkan dalam sistem klasifikasi otomatis di industri akuakultur. Bagi praktisi, model ini dapat dimanfaatkan sebagai alat bantu identifikasi varietas ikan hias secara cepat dan konsisten, sehingga mengurangi ketergantungan pada pengamatan manual yang rentan subjektivitas, mendukung proses grading kualitas ikan sebelum distribusi, serta membantu peningkatan akurasi dalam penentuan harga dan strategi pemasaran di pasar ikan hias. Sebagai saran untuk penelitian selanjutnya, disarankan untuk mengeksplorasi teknik augmentasi berbasis generative adversarial networks (GAN) guna memperluas variasi sintetik citra, serta mengadopsi pendekatan transfer learning dari arsitektur pretrained seperti EfficientNet atau ResNet untuk meningkatkan generalisasi model terutama dalam skenario dengan keterbatasan data.

DAFTAR PUSTAKA

- Ahmed, M. S., Aurpa, T. T., & Azad, M. A. K. (2022). Fish Disease Detection Using Image Based Machine Learning Technique in Aquaculture. *Journal of King Saud University - Computer and Information Sciences*, 34(8), 5170–5182. <https://doi.org/10.1016/j.jksuci.2021.05.003>
- Aristoteles, A., Heningtyas, Y., Syarif, A., & Pratidina, G. (2021). Implementation of Gabor Filter for Carassius Auratus's Identification. *International Journal on Advanced Science, Engineering and Information Technology*, 11(2), 566–571. <https://doi.org/10.18517/ijaseit.11.2.8128>
- Biondo, M. V., & Burki, R. P. (2020). A systematic review of the ornamental fish trade with emphasis on coral reef fishes—an impossible task. *Animals*, 10(11), 1–21. <https://doi.org/10.3390/ani10112014>
- Cermakova, E., Lencova, S., Mukherjee, S., Horka, P., Vobruba, S., Demnerova, K., & Zdenkova, K. (2023). Identification of Fish Species and Targeted Genetic Modifications Based on DNA Analysis: State of the Art. *Foods*, 12(1), 1–45. <https://doi.org/10.3390/foods12010228>
- Haddad, D. M. D., & Mohammed, F. H. (2024). A Convolutional Neural Network Approach for Precision Fish Disease Detection. *Evolutionary Studies in Imaginative Culture*, 8, 1018–1033. <https://doi.org/10.70082/esiculture.vi.1234>
- Hu, X., & Lima, M. F. (2024). The association between maintenance and biodiversity in urban green spaces: A review. *Landscape and Urban Planning*, 251(July), 105153. <https://doi.org/10.1016/j.landurbplan.2024.105153>
- Li, D., Su, H., Jiang, K., Liu, D., & Duan, X. (2022). Fish Face Identification Based on Rotated Object Detection: Dataset and Exploration. *Fishes*, 7(5). <https://doi.org/10.3390/fishes7050219>
- Li, H., Rajbahadur, G. K., Lin, D., Bezemer, C. P., & Jiang, Z. M. (2024). Keeping Deep Learning Models in Check: A History-Based Approach to Mitigate Overfitting. *IEEE Access*, 12, 70676–70689. <https://doi.org/10.1109/ACCESS.2024.3402543>
- Liu, Z., Xu, Z., Jin, J., Shen, Z., & Darrell, T. (2023). Dropout Reduces Underfitting. *Proceedings of Machine Learning Research*, 202(June), 21715–21729. <https://doi.org/10.48550/arXiv.2303.01500>
- Maia, C. M., Gauy, A. C. S., & Gonçalves-de-Freitas, E. (2025). Fish Welfare in the Ornamental Trade: Stress Factors, Legislation, and Emerging Initiatives. *Fishes*, 10(5), 1–16. <https://doi.org/10.3390/fishes10050224>
- Moralista, R. B., & Rueda, R. B. (2023). E-Learning Development as an E-Teaching Innovation in Graduate Education. *Journal of Advance Zoology*, 44(3), 1770–1780. <https://doi.org/10.17762/jaz.v44iS-3.1767>
- Multajam, R., Ayob, A. F. M., Sanjaya, W. S. M., Sambas, A., Rusyn, V., & Samila, A. (2024). Real-Time Detection and Classification of Fish in Underwater Environment Using Yolov5: a Comparative Study of Deep Learning Architectures. *Informatyka, Automatyka, Pomiary w Gospodarce i Ochronie*

Srodowiska, 14(3), 91–95. <https://doi.org/10.35784/iapgos.6022>

- Mol, J., Jose, S. A. (2024). Fish Species Classification Using Deep Learning and Appearance-Based Feature Extraction. *Journal of Electrical Systems*, 20(2), 2531–2546. <https://doi.org/10.52783/jes.2026>
- Rodiah, R., Susetianingtias, D. T., & Patriya, E. (2024). Identifikasi Fitur Suara Menggunakan Model Convolutional Neural Network (CNN) pada Speech-to-Text (STT). *Decode: Jurnal Pendidikan Teknologi Informasi*, 4(3), 809–820. <https://doi.org/10.51454/decode.v4i3.631>
- Salehin, I., & Kang, D. K. (2023). A Review on Dropout Regularization Approaches for Deep Neural Networks within the Scholarly Domain. *Electronics (Switzerland)*, 12(14). <https://doi.org/10.3390/electronics12143106>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>
- Suhana, R., Mahmudy, W. F., & Budi, A. S. (2022). Fish Image Classification Using Adaptive Learning Rate In Transfer Learning Method. *Knowledge Engineering and Data Science*, 5(1), 67. <https://doi.org/10.17977/um018v5i12022p67-77>
- Tarihoran, A. D. B., Hubeis, M., Jahroh, S., & Zulbainarni, N. (2024). Building a sustainable institutional model for ornamental fish farming export villages in Indonesia. *International Journal of Agricultural Sustainability*, 22(1), 1–24. <https://doi.org/10.1080/14735903.2024.2401203>
- Wojciuk, M., Swiderska-Chadaj, Z., Siwek, K., & Gertych, A. (2024). Improving classification accuracy of fine-tuned CNN models: Impact of hyperparameter optimization. *Heliyon*, 10(5), e26586. <https://doi.org/10.1016/j.heliyon.2024.e26586>
- Zhu, Z. (2024). Systematic Optimization of Overfitting Problem in Machine Learning. *Highlights in Science, Engineering and Technology*, 111, 353–359. <https://doi.org/10.54097/3tkzrj84>