Implementasi Website Klasifikasi Jenis Ikan Koi Menggunakan Multi-Channel GLCM dan Linear Support Vector Machine

Samuel Wijaya[1], Fetty Tri Anggraeny[2], Hendra Maulana[3]
Informatika, Universitas Pembangunan Nasional "Veteran" Jawa Timur
e-mail: 21081010249@student.upnjatim.ac.id[1], fettyanggraeny.if@upnjatim.ac.id[2], hendra.maulana.if@upnjatim.ac.id[3]

Kata Kunci:

Klasifikasi ikan koi
Multi-channel GLCM
SVM
Kernel RBF
Website

ABSTRAK

Identifikasi jenis ikan koi secara manual masih sulit karena beberapa varietas memiliki kemiripan warna, pola, dan tekstur. Penelitian ini mengimplementasikan website klasifikasi Kohaku, Taisho Sanke, Showa Sanshoku, dan Tancho menggunakan multi-channel Gray-Level Co-occurrence Matrix (GLCM) dan Support Vector Machine (SVM). Sebanyak 400 citra asli dibagi sebelum augmentasi menjadi 280 citra latih, 60 validasi, dan 60 uji. Augmentasi hanya diterapkan pada data latih sehingga diperoleh 1.120 citra latih. Ekstraksi GLCM pada kanal Gray+RGB menghasilkan 320 fitur per citra. Empat kernel SVM dibandingkan melalui five-fold source-grouped cross-validation. SVM Linear dengan C=1,0 terpilih dan mencapai akurasi uji 81,67% dengan macro F1-score 0,813. Pada website, 320 fitur dimasukkan langsung ke pipeline Joblib yang memuat StandardScaler dan SVM. Website menampilkan kelas prediksi serta status BENAR/SALAH berdasarkan kelas aktual yang dipilih pengguna. Implementasi ini menjaga konsistensi preprocessing dan inferensi dengan pipeline pelatihan.

Keyword:

Koi classification
Multi-channel GLCM
SVM
RBF kernel
Website

ABSTRACT

Manual identification of koi varieties is difficult because several classes share similar colors, patterns, and textures. This study implements a web-based classifier for Kohaku, Taisho Sanke, Showa Sanshoku, and Tancho using multi-channel Gray-Level Co-occurrence Matrix (GLCM) features and Support Vector Machine (SVM). Four hundred original images were split before augmentation into 280 training, 60 validation, and 60 test images. Augmentation was applied only to training data, producing 1,120 training images. GLCM extraction from Gray+RGB channels produced 320 features per image. Four SVM kernels were compared using five-fold source-grouped cross-validation. Linear SVM with C = 1.0 was selected and achieved 81.67% test accuracy with a macro F1-score of 0.813. In the website, the 320-feature vector is passed directly to a Joblib pipeline containing StandardScaler and SVM. The interface displays the predicted class and a CORRECT/INCORRECT status based on the user-selected actual class. This implementation keeps preprocessing and inference consistent with the training pipeline.

Copyright © SENASIF 2026
ISSN: 2598-0076

I. PENDAHULUAN

Ikan koi (Cyprinus rubrofuscus) merupakan ikan hias air tawar yang varietasnya dibedakan melalui kombinasi warna tubuh, distribusi pola, dan tampilan permukaan. Klasifikasi varietas yang konsisten penting bagi penghobi, pembudidaya, penjual, dan katalog digital karena ikan dengan tampilan yang mirip dapat ditempatkan pada kelas berbeda ketika penilaian hanya mengandalkan pengamatan subjektif. Klasifikasi berbasis citra menyediakan pendekatan yang lebih terukur dengan mengubah karakteristik visual menjadi representasi numerik yang dapat dievaluasi oleh model komputasi [1]. Penelitian ini berfokus pada klasifikasi citra diam dan tidak mengklaim sebagai sistem identifikasi untuk kondisi kolam yang tidak terkendali.

Computer vision telah digunakan untuk pengenalan ikan pada foto terkontrol, citra bawah air, dan pemantauan habitat. Sejumlah penelitian memanfaatkan transfer learning, convolutional neural network, vision transformer, dan arsitektur deep learning lainnya dengan hasil yang kuat pada berbagai tugas klasifikasi ikan [2][3][4][5]. Namun, kinerja metode tersebut dipengaruhi oleh skala dataset, kondisi akuisisi citra, konfigurasi pelatihan, dan rancangan validasi, sehingga angka akurasi antarpenelitian tidak dapat dibandingkan secara langsung [1][4].

Pada dataset berukuran sedang, pipeline berbasis handcrafted features tetap relevan karena menghasilkan deskriptor yang eksplisit dan tidak memerlukan pembelajaran representasi end-to-end. Gray-Level Co-occurrence Matrix (GLCM) dapat menangkap informasi tekstur melalui hubungan spasial antarnilai intensitas pada jarak dan orientasi tertentu. Properti contrast, dissimilarity, homogeneity, energy, dan correlation merangkum karakteristik organisasi tekstur lokal [6]. Penerapan GLCM secara terpisah pada grayscale dan kanal warna mempertahankan informasi struktur intensitas spesifik kanal yang dapat berkurang ketika citra hanya dikonversi ke grayscale [7].

GLCM tetap memiliki keterbatasan. Statistik GLCM global tidak secara eksplisit menyimpan posisi anatomis, bentuk geometris, kontinuitas, atau luas relatif suatu corak. Keterbatasan ini penting pada koi karena Kohaku didominasi area merah dan putih, Taisho Sanke dan Showa Sanshoku sama-sama memiliki komponen merah, putih, dan hitam, sedangkan Tancho diasosiasikan dengan tanda merah yang terkonsentrasi di bagian kepala. Oleh sebab itu, fitur multi-channel GLCM diperlakukan sebagai representasi tekstur dan struktur intensitas, bukan sebagai representasi lengkap identitas varietas.

Support Vector Machine (SVM) sesuai untuk fitur handcrafted berdimensi tinggi karena membangun batas keputusan berbasis margin dan dapat mengubah geometri pemisahan melalui fungsi kernel [8]. Kernel Linear, Radial Basis Function (RBF), Polynomial, dan Sigmoid membentuk relasi antarsampel secara berbeda. Parameter C mengontrol trade-off antara lebar margin dan kesalahan klasifikasi, sedangkan gamma memengaruhi kernel nonlinier. Karena konfigurasi tersebut

Copyright © SENASIF 2026
ISSN: 2598-0076

dapat mengubah batas keputusan secara material, pemilihan kernel dan hiperparameter harus dilakukan pada proses validasi, bukan berdasarkan satu hasil pengujian akhir.

Isu metodologis utama pada dataset citra yang diaugmentasi adalah independensi citra sumber. Apabila turunan hasil augmentasi dari satu citra asli tersebar ke data latih dan data uji, data uji dapat memiliki kemiripan yang sangat dekat dengan data latih dan menghasilkan estimasi performa yang terlalu optimistis. Bias juga muncul ketika hasil data uji berulang kali digunakan untuk memilih kernel, hiperparameter, atau skema pembagian data. Untuk mengurangi risiko tersebut, penelitian ini membagi 400 citra asli sebelum augmentasi, menerapkan augmentasi hanya pada data latih, menggunakan source-grouped cross-validation, dan mempertahankan data uji akhir untuk satu evaluasi final [9].

Kontribusi penelitian ini adalah mengintegrasikan model klasifikasi SVM terpilih ke dalam website yang dapat digunakan melalui antarmuka sederhana, tanpa mengabaikan rancangan evaluasi model. Empat kernel SVM, yaitu Linear, RBF, Polynomial, dan Sigmoid, dibandingkan pada representasi multi-channel GLCM berdimensi 320 dengan source-grouped cross-validation. Model terbaik kemudian disimpan sebagai pipeline yang menggabungkan StandardScaler dan SVM, lalu digunakan sebagai komponen prediksi pada backend Flask. Dengan demikian, penelitian tidak hanya mengevaluasi performa klasifikasi, tetapi juga menerapkan pipeline preprocessing, ekstraksi fitur, normalisasi internal, prediksi, serta penampilan hasil ke dalam sistem berbasis web.

II. METODE

Penelitian menggunakan desain eksperimental dan implementatif untuk membangun website klasifikasi citra koi menggunakan fitur multi-channel GLCM dan SVM. Tahap eksperimen digunakan untuk memilih konfigurasi SVM dengan menjaga independensi citra sumber, mencegah augmentation leakage, dan memisahkan data uji akhir dari proses pemilihan model. Tahap implementasi menggunakan model terpilih pada backend Flask sehingga pengguna dapat mengunggah citra dan memperoleh hasil klasifikasi melalui antarmuka website.

Dataset dan Augmentasi

Dataset sekunder diperoleh dari Dataset Images Koi pada Kaggle [10]. Empat kelas yang digunakan adalah Kohaku, Taisho Sanke, Showa Sanshoku, dan Tancho. Setiap kelas memiliki 100 citra asli sehingga total dataset awal berjumlah 400 citra. Sebelum augmentasi, setiap kelas dibagi menjadi 70 citra latih, 15 citra validasi, dan 15 citra uji. Dengan demikian, terdapat 280 citra sumber untuk pelatihan, 60 untuk validasi, dan 60 untuk pengujian akhir. Identitas citra sumber dibuat saling terpisah agar satu citra asli tidak memberikan informasi pada lebih dari satu subset [9].

Augmentasi hanya diterapkan pada 280 citra latih. Setiap citra latih menghasilkan tiga citra turunan dari kumpulan transformasi horizontal flipping, rotasi, perubahan kecerahan, perubahan kontras, dan zoom. Randomisasi dikendalikan dengan random seed 42. Rotasi berada sekitar ±15°, skala kontras 0,80-1,20, dan zoom 1,05-1,20. Hasilnya, data latih terdiri atas 280 citra asli dan 840

Copyright © SENASIF 2026

ISSN: 2598-0076

citra hasil augmentasi, atau 1.120 citra. Data validasi dan data uji tetap berisi citra asli tanpa augmentasi [11].

Tabel 1. Pembagian dataset dan augmentasi

Subset	Citra asli	Citra augmentasi	Total
Latih	280	840	1.120
Validasi	60	0	60
Uji	60	0	60

Preprocessing Citra

Setiap citra diubah ukurannya menjadi 256 × 256 piksel agar seluruh sampel memiliki dimensi spasial yang konsisten. Selanjutnya, citra direpresentasikan sebagai grayscale serta kanal red, green, dan blue. Grayscale mempertahankan struktur luminansi, sedangkan kanal RGB mempertahankan hubungan intensitas spesifik warna. Setiap kanal diproses secara terpisah pada tahap ekstraksi GLCM sebelum seluruh blok fitur digabungkan.

Ekstraksi Fitur Multi-Channel GLCM

Sebelum pembentukan GLCM, nilai intensitas setiap kanal dikuantisasi menjadi 64 tingkat untuk mengurangi dimensi matriks tanpa menghilangkan variasi hubungan intensitas lokal secara berlebihan. GLCM dihitung pada jarak piksel 1, 2, dan 3 serta orientasi 0°, 45°, 90°, dan 135°. Lima properti yang digunakan adalah contrast, dissimilarity, homogeneity, energy, dan correlation [6].

Untuk setiap properti, 12 nilai hasil kombinasi tiga jarak dan empat orientasi dipertahankan. Empat statistik ringkas, yaitu mean, standar deviasi, minimum, dan maksimum, juga dihitung. Setiap properti menghasilkan 16 nilai, sehingga satu kanal menghasilkan 80 fitur. Empat kanal menghasilkan 320 fitur per citra. Keempat blok fitur kemudian dikonkatenasi menjadi satu vektor numerik sebagai masukan SVM.

Normalisasi Fitur

Properti GLCM memiliki rentang numerik yang berbeda dan dapat memengaruhi klasifikator berbasis margin. StandardScaler digunakan untuk menstandarkan setiap fitur menggunakan rata-rata dan standar deviasi yang dihitung hanya dari data pelatihan [12]. Pada cross-validation, scaler dipasang pada bagian training setiap fold dan diterapkan pada fold yang ditahan. Untuk model final, scaler dipasang ulang bersama model pada gabungan data latih dan validasi sebelum diterapkan pada data uji. Prosedur ini mencegah informasi dari data evaluasi masuk ke proses preprocessing [9].

Klasifikasi SVM dan Pemilihan Hiperparameter

Empat kernel SVM dievaluasi menggunakan representasi 320 fitur yang sama, yaitu Linear, RBF, Polynomial, dan Sigmoid. Nilai C yang diuji adalah 0,1; 1; dan 10 untuk seluruh kernel. Untuk RBF, Polynomial, dan Sigmoid, gamma yang diuji adalah scale, auto, 0,001, 0,01, dan 0,1. Kernel Polynomial juga diuji pada degree 2 dan 3. Hiperparameter tidak dipilih berdasarkan hasil data uji final, tetapi dirangking menggunakan cross-validation yang hanya menggunakan data latih.

Copyright © SENASIF 2026
ISSN: 2598-0076

Skenario Evaluasi

Pemilihan model menggunakan five-fold Stratified Group K-Fold cross-validation pada data latih dengan identitas citra sumber sebagai variabel kelompok. Satu citra asli dan seluruh turunannya selalu berada pada fold yang sama. Konfigurasi dengan rata-rata akurasi cross-validation tertinggi dipilih, dengan macro F1-score sebagai kriteria sekunder ketika hasil kandidat berdekatan. Model terpilih kemudian diuji pada 60 citra validasi tanpa mengubah hiperparameter. Setelah validasi, model dipasang ulang pada gabungan data latih dan validasi, kemudian dievaluasi satu kali pada 60 citra uji yang tidak pernah digunakan untuk pemilihan model. Selain itu, dilakukan lima kali pengulangan five-fold source-grouped cross-validation untuk menilai variasi performa [13][14].

Analisis Ablasi Kanal

Analisis ablasi kanal dilakukan untuk menilai kontribusi representasi Gray (80 fitur), Red (80), Green (80), Blue (80), RGB (240), dan Gray+RGB (320). Untuk setiap representasi, kernel dan hiperparameter dipilih secara independen menggunakan five-fold Stratified Group K-Fold pada data latih dengan source_id sebagai kelompok. Konfigurasi terpilih kemudian dibandingkan hanya pada 60 citra validasi, sedangkan final test set tidak digunakan. Repeated five-by-five grouped cross-validation dan exact McNemar pada prediksi validasi digunakan untuk menilai variasi dan perbedaan berpasangan. Ablasi diperlakukan sebagai analisis sensitivitas sekunder dan tidak dijalankan pada app.py; website tetap menggunakan representasi utama Gray+RGB 320 fitur yang telah dikunci untuk model deployment

Metrik Evaluasi

Performa dievaluasi menggunakan confusion matrix, akurasi multiclass, precision, recall, F1-score per kelas, serta macro precision, macro recall, dan macro F1-score [15][16]. Ketidakpastian akurasi akhir dihitung melalui 5.000 bootstrap resamples untuk memperoleh interval kepercayaan 95%. Uji exact McNemar berpasangan digunakan untuk membandingkan prediksi model Linear dan RBF pada citra uji yang sama. Nilai p diinterpretasikan pada α=0,05, dan hasil yang tidak signifikan tidak digunakan sebagai bukti superioritas kernel.

$$Accuracy = \frac{\sum_i c_{ii}}{\sum_i \sum_j c_{ij}} \quad (1)$$

$$Precision_i = \frac{TP_i}{TP_i + FP_i} \quad (2)$$

$$Recall_i = \frac{TP_i}{TP_i + FN_i} \quad (3)$$

$$F1_i = 2x \frac{Precision_i \; x \; Recall_i}{Precision_i + Recall_i} \quad (4)$$

Copyright © SENASIF 2026

ISSN: 2598-0076

Implementasi Website

Implementasi website menggunakan backend Flask yang memuat final_svm_pipeline.pkl hasil pelatihan reviewer-safe. File tersebut berisi StandardScaler dan model SVM dalam satu pipeline sehingga fitur tidak dinormalisasi secara terpisah. Ketika pengguna mengunggah citra, OpenCV mengubah ukuran citra menjadi 256 × 256 piksel, membentuk kanal gray, red, green, dan blue, melakukan kuantisasi 64 level, lalu menghitung GLCM pada jarak 1, 2, dan 3 piksel serta sudut 0°, 45°, 90°, dan 135°. Lima properti menghasilkan 80 fitur per kanal atau 320 fitur dengan urutan Gray-Red-Green-Blue. Vektor tersebut dikirim langsung ke pipeline dan SVM Linear C=1,0 menghasilkan kelas prediksi. Analisis ablasi tidak menjadi bagian inferensi website karena fungsinya hanya untuk evaluasi offline kontribusi kanal

Pengujian Fungsional Website

Pengujian fungsional dilakukan untuk memastikan implementasi kode dan model mempunyai alur yang sama dengan tahap pelatihan. Pengujian mencakup validasi unggahan citra, resize 256 × 256 piksel, pembentukan kanal Gray+RGB, kuantisasi 64 level, ekstraksi tepat 320 fitur, pemanggilan final_svm_pipeline.pkl, prediksi kelas, perbandingan dengan kelas aktual, serta penampilan hasil pada halaman Flask. Pengujian fungsi website tidak digunakan untuk menghitung akurasi model. Performa klasifikasi tetap mengacu pada 60 citra uji independen.

III. HASIL DAN PEMBAHASAN

Hasil Cross-Validation dan Pemilihan Model

Five-fold source-grouped cross-validation pada data latih menunjukkan bahwa SVM Linear dengan C=1,0 menghasilkan rata-rata akurasi tertinggi, yaitu 72,23% dengan standar deviasi 6,24% dan macro F1-score 0,721. Konfigurasi RBF terbaik menggunakan C=10 dan gamma=0,001 dengan akurasi 70,71% dan macro F1-score 0,704. Polynomial dan Sigmoid masing-masing mencapai 66,79% dan 57,59%. Berdasarkan ranking tersebut, SVM Linear dipilih sebelum data uji final diperiksa.

Tabel 2. Hasil cross-validation terbaik setiap kernel SVM

Kernel	C terbaik	Gamma/degree	Akurasi CV	Macro F1
Linear	1,0	N/A	72,23%	0,721
RBF	10	0,001	70,71%	0,704
Polynomial	10	0,01 / d=3	66,79%	0,668
Sigmoid	1	0,001	57,59%	0,569

Kinerja Pengujian Akhir dan Ketidakpastian

Setelah konfigurasi Linear dipasang ulang pada gabungan data latih dan validasi, model dievaluasi pada 60 citra uji asli yang tidak diaugmentasi. Model mengklasifikasikan 49 dari 60 citra dengan benar sehingga mencapai akurasi 81,67%, macro precision 0,814, macro recall 0,817, dan macro F1-score 0,813. Bootstrap 5.000 iterasi menghasilkan interval kepercayaan 95% sebesar

Copyright © SENASIF 2026
ISSN: 2598-0076

71,67%-91,67%. Repeated five-by-five source-grouped cross-validation pada data latih menghasilkan akurasi rata-rata 71,80% ± 5,22%, sehingga skor 81,67% perlu dibaca sebagai satu realisasi pada split uji final, bukan sebagai estimasi stabil untuk seluruh kondisi penggunaan.

Tabel 3. Kinerja Pengujian Akhir dan Ketidakpastian

Metrik	Nilai
Akurasi	81,67%
Macro precision	0,814
Macro recall	0,817
Macro F1-score	0,813
95% CI akurasi	71,67%-91,67%
Prediksi benar	49/60
Repeated grouped CV	71,80% ± 5,22%

Confusion Matrix dan Kinerja per Kelas

Confusion matrix menunjukkan bahwa seluruh 15 citra Showa Sanshoku diklasifikasikan dengan benar. Kohaku menghasilkan 13 prediksi benar, Taisho Sanke 11, dan Tancho 10. Kesalahan Kohaku hanya berupa dua prediksi sebagai Tancho. Kesalahan Taisho Sanke tersebar ke Kohaku, Showa Sanshoku, dan Tancho. Tancho dua kali diprediksi sebagai Kohaku, dua kali sebagai Taisho Sanke, dan sekali sebagai Showa Sanshoku.

Tabel 4. Confusion Matrix SVM Linear pada Data Uji

Aktual/Prediksi	Kohaku	Taisho Sanke	Showa Sanshoku	Tancho
Kohaku	13	0	0	2
Taisho Sanke	1	11	1	2
Showa Sanshoku	0	0	15	0
Tancho	2	2	1	10

Pada tingkat kelas, Showa Sanshoku memiliki recall tertinggi sebesar 1,000 dan F1-score 0,938. Tancho memiliki recall terendah sebesar 0,667 dan F1-score 0,690. Kohaku menghasilkan F1-score 0,839 dan Taisho Sanke 0,786. Pada perbandingan kernel berpasangan, SVM RBF mencapai akurasi 75,00%, sedangkan Linear mencapai 81,67%. Linear benar pada tujuh citra yang salah diprediksi RBF, sementara RBF benar pada tiga citra yang salah diprediksi Linear. Uji exact McNemar menghasilkan $p=0,34375$, sehingga perbedaan numerik tersebut tidak signifikan pada $\alpha=0,05$.

Tabel 5. Metrik Evaluasi per Kelas

Kelas	Precision	Recall	F1-score
Kohaku	0,813	0,867	0,839
Taisho Sanke	0,846	0,733	0,786
Showa Sanshoku	0,882	1,000	0,938
Tancho	0,714	0,667	0,690
Macro average	0,814	0,817	0,813

Hasil Analisis Ablasi Kanal

Analisis ablasi dilakukan tanpa menggunakan final test set. RGB menghasilkan akurasi validasi tertinggi sebesar 83,33% dengan macro F1-score 0,832, sedangkan Gray+RGB menghasilkan 81,67% dengan macro F1-score 0,814. Akurasi cross-validation keduanya juga berdekatan, yaitu

Copyright © SENASIF 2026

ISSN: 2598-0076

72,32% untuk RGB dan 72,23% untuk Gray+RGB. Hasil ini menunjukkan bahwa informasi multi-channel warna memberi kontribusi penting, tetapi penambahan blok grayscale di atas RGB belum menunjukkan keuntungan tambahan pada data validasi.

Tabel 6. Hasil Analisis Ablasi Kanal pada Data Validasi

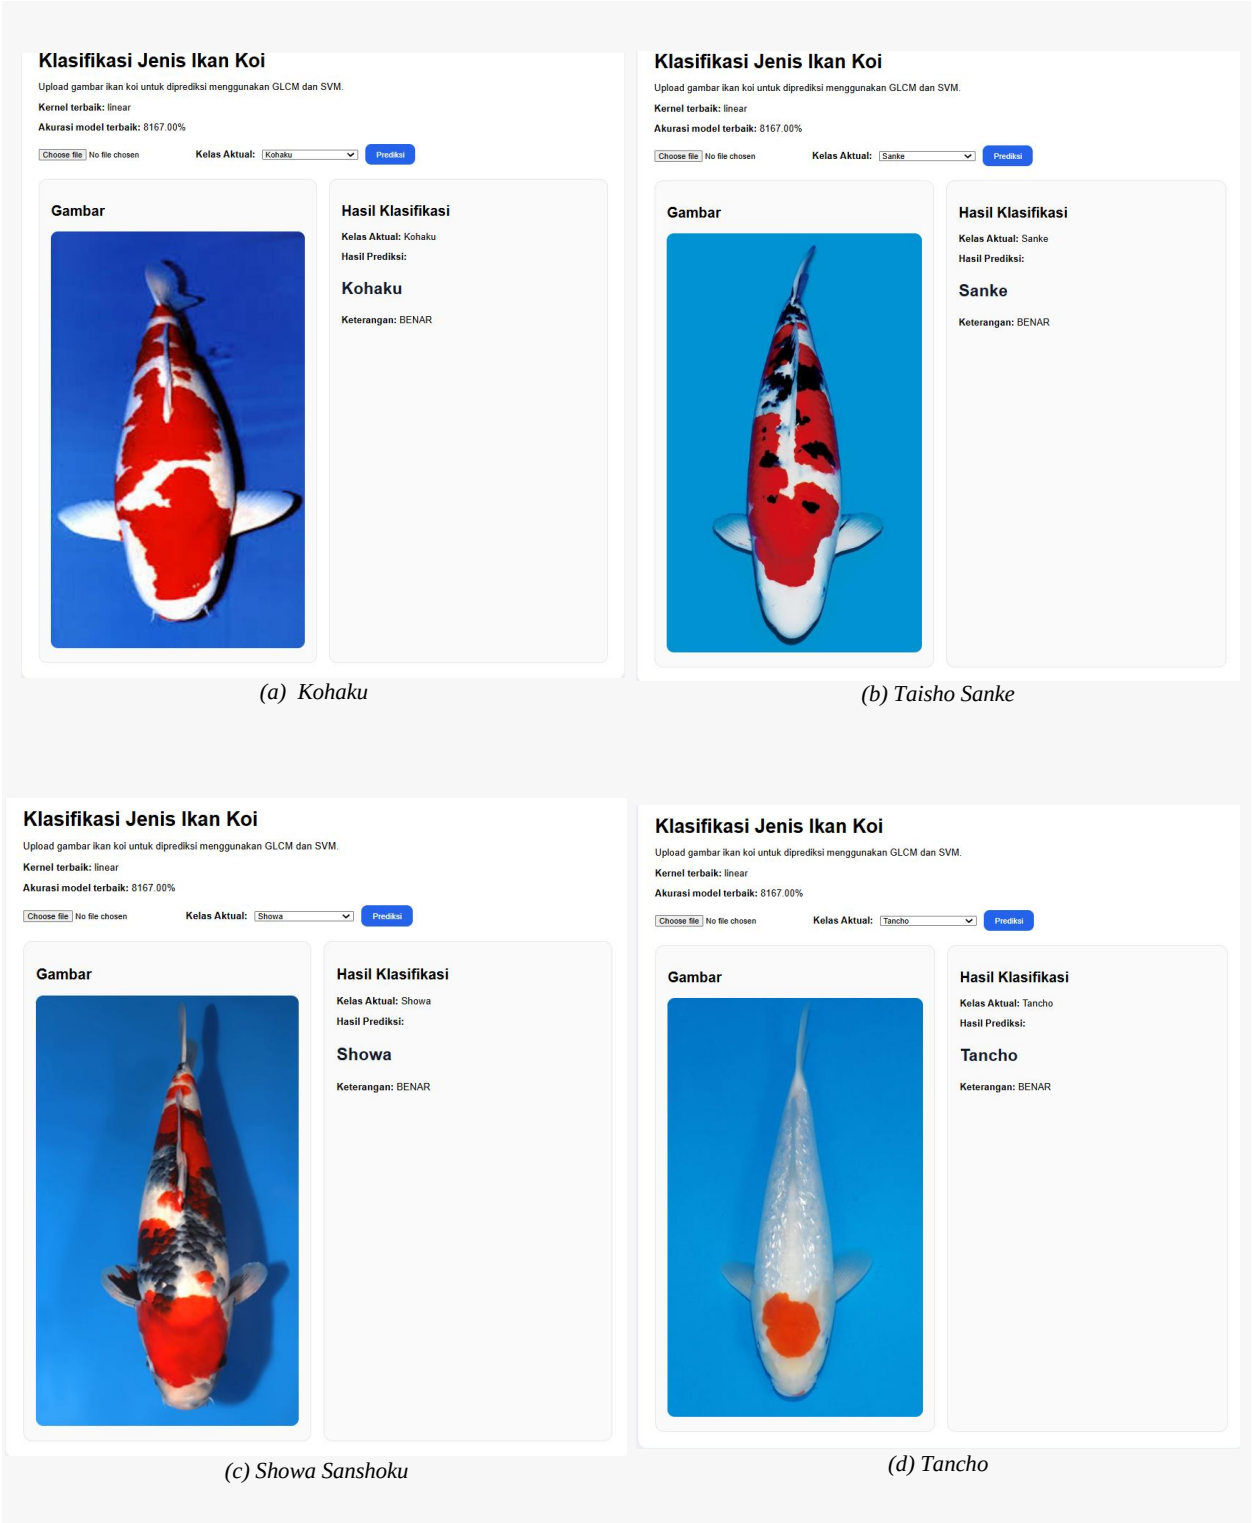
Representasi	Fitur	Akurasi CV	Akurasi validasi	Macro F1
Gray	80	58,93%	61,67%	0,616
Red	80	60,63%	68,33%	0,680
Green	80	53,30%	60,00%	0,602
Blue	80	56,87%	56,67%	0,562
RGB	240	72,32%	83,33%	0,832
Gray+RGB	320	72,23%	81,67%	0,814

Exact McNemar pada data validasi menunjukkan Gray+RGB berbeda signifikan terhadap Gray (p=0,007538), Green (p=0,004425), dan Blue (p=0,008130), tetapi tidak terhadap Red (p=0,076813) maupun RGB (p=1,000000). Karena ablasi merupakan analisis sekunder, hasil tersebut tidak digunakan untuk mengganti representasi model utama setelah pipeline final ditetapkan. Website tetap menjalankan Gray+RGB 320 fitur agar konsisten dengan final_svm_pipeline.pkl.

Implementasi dan Pengujian Website

Model Linear SVM yang dipilih melalui source-grouped cross-validation diimplementasikan pada backend Flask melalui final_svm_pipeline.pkl. Citra masukan diubah menjadi 256 × 256 piksel, dibentuk menjadi kanal Gray+RGB, dikuantisasi menjadi 64 level, lalu diekstraksi menjadi 320 fitur GLCM dengan urutan Gray–Red–Green–Blue. Vektor fitur dikirim langsung ke pipeline yang telah memuat StandardScaler dan SVM. Pada pengujian fungsional menggunakan masing-masing satu contoh citra Kohaku, Taisho Sanke, Showa Sanshoku, dan Tancho, website berhasil menampilkan prediksi yang sesuai dengan kelas aktual dan status BENAR. Empat hasil tersebut digunakan untuk membuktikan fungsi integrasi website, sedangkan performa model secara keseluruhan tetap mengacu pada 60 citra uji independen dengan akurasi 81,67% dan macro F1-score 0,813

Copyright © SENASIF 2026
ISSN: 2598-0076



(a) Kohaku *(b) Taisho Sanke*

(c) Showa Sanshoku *(d) Tancho*

Gambar 1. Hasil Klasifikasi Empat Jenis Ikan Koi melalui Website

Tabel 7. Hasil Pengujian Klasifikasi melalui Website

Kelas aktual	Prediksi website	Status
Kohaku	Kohaku	BENAR
Taisho Sanke	Taisho Sanke	BENAR
Showa Sanshoku	Showa Sanshoku	BENAR
Tancho	Tancho	BENAR

Copyright © SENASIF 2026
ISSN: 2598-0076

Keempat contoh pada Gambar 1 menunjukkan keberhasilan alur inferensi dari unggah citra hingga keluaran prediksi. Hasil BENAR pada empat contoh tidak berarti akurasi website 100%, karena ukuran performa tetap ditentukan melalui pengujian pada seluruh data uji independen.

IV. SIMPULAN

Penelitian ini berhasil mengimplementasikan website klasifikasi jenis ikan koi menggunakan fitur multi-channel Gray-Level Co-occurrence Matrix (GLCM) dan algoritma Support Vector Machine (SVM). Sistem yang dibangun mampu mengintegrasikan proses ekstraksi fitur, klasifikasi, dan prediksi ke dalam aplikasi berbasis web.

Pendekatan berbasis karakteristik tekstur dan warna dapat digunakan sebagai alternatif untuk membantu proses identifikasi varietas ikan koi. Implementasi pipeline yang konsisten antara proses pelatihan model dan proses inferensi pada website mendukung penerapan sistem klasifikasi yang lebih terstruktur.

DAFTAR RUJUKAN

[1] A. Saleh, M. Sheaves, and M. Rahimi Azghadi, "Computer vision and deep learning for fish classification in underwater habitats: A survey," *Fish and Fisheries*, vol. 23, no. 4, pp. 977–999, Jul. 2022, doi: 10.1111/faf.12666.

[2] B. Gong, K. Dai, J. Shao, L. Jing, and Y. Chen, "Fish-TViT: A novel fish species classification method in multi water areas based on transfer learning and vision transformer," *Heliyon*, vol. 9, no. 6, p. e16761, Jun. 2023, doi: 10.1016/j.heliyon.2023.e16761.

[3] H. Qu, G.-G. Wang, Y. Li, X. Qi, and M. Zhang, "ConvFishNet: An efficient backbone for fish classification from composited underwater images," *Inf. Sci. (N. Y).*, vol. 679, p. 121078, Sep. 2024, doi: 10.1016/j.ins.2024.121078.

[4] A. Saleh, M. Sheaves, D. Jerry, and M. Rahimi Azghadi, "Applications of deep learning in fish habitat monitoring: A tutorial and survey," *Expert Syst. Appl.*, vol. 238, p. 121841, Mar. 2024, doi: 10.1016/j.eswa.2023.121841.

[5] J. Deka, S. Laskar, and B. Baklial, "Automated Freshwater Fish Species Classification using Deep CNN," *Journal of The Institution of Engineers (India): Series B*, vol. 104, no. 3, pp. 603–621, Jun. 2023, doi: 10.1007/s40031-023-00883-2.

[6] L. M. Davidovic *et al.*, "Gray-Level Co-occurrence Matrix Analysis for the Detection of Discrete, Ethanol-Induced, Structural Changes in Cell Nuclei: An Artificial Intelligence Approach," *Microscopy and Microanalysis*, vol. 28, no. 1, pp. 265–271, Feb. 2022, doi: 10.1017/S1431927621013878.

Copyright © SENASIF 2026
ISSN: 2598-0076

[7] W. Zhang, B. Yu, G. Li, P. Zhuang, Z. Liang, and W. Zhao, “Unified multi-color-model-learning-based deep support vector machine for underwater image classification,” *Eng. Appl. Artif. Intell.*, vol. 138, p. 109437, Dec. 2024, doi: 10.1016/j.engappai.2024.109437.

[8] K.-L. Du, B. Jiang, J. Lu, J. Hua, and M. N. S. Swamy, “Exploring Kernel Machines and Support Vector Machines: Principles, Techniques, and Future Directions,” *Mathematics*, vol. 12, no. 24, p. 3935, Dec. 2024, doi: 10.3390/math12243935.

[9] I. E. Tampu, A. Eklund, and N. Haj-Hosseini, “Inflation of test accuracy due to data leakage in deep learning-based classification of OCT images,” *Sci. Data*, vol. 9, no. 1, p. 580, Sep. 2022, doi: 10.1038/s41597-022-01618-6.

[10] Fariz Prasetya Putra, “Dataset Images Koi,” 2022.

[11] K. Alomar, H. I. Aysel, and X. Cai, “Data Augmentation in Classification and Segmentation: A Survey and New Strategies,” *J. Imaging*, vol. 9, no. 2, p. 46, Feb. 2023, doi: 10.3390/jimaging9020046.

[12] L. B. V. de Amorim, G. D. C. Cavalcanti, and R. M. O. Cruz, “The choice of scaling technique matters for classification performance,” *Appl. Soft Comput.*, vol. 133, p. 109924, Jan. 2023, doi: 10.1016/j.asoc.2022.109924.

[13] O. Rainio, J. Teuho, and R. Klén, “Evaluation metrics and statistical tests for machine learning,” *Sci. Rep.*, vol. 14, no. 1, p. 6086, Mar. 2024, doi: 10.1038/s41598-024-56706-x.

[14] D. Powers and Ailab, “Evaluation: From precision, recall and F-measure to ROC, informedness, markedness & correlation,” *J. Mach. Learn. Technol*, vol. 2, pp. 2229–3981, Jan. 2011, doi: 10.9735/2229-3981.

[15] J. T. Hancock, T. M. Khoshgoftaar, and J. M. Johnson, “Evaluating classifier performance with highly imbalanced Big Data,” *J. Big Data*, vol. 10, no. 1, p. 42, Apr. 2023, doi: 10.1186/s40537-023-00724-5.

[16] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning representations by back-propagating errors,” *Nature*, vol. 323, no. 6088, pp. 533–536, Oct. 1986, doi: 10.1038/323533a0.

Copyright © SENASIF 2026

ISSN: 2598-0076