

DETEKSI KEPITING MOLTING MENGGUNAKAN TEKNIKKLASIFIKASI MACHINE LEARNING

Runal Rezkiawan Baharuddin¹, Muhammad Niswar², Amil Ahmad Ilham³
Prodi Informatika, Universitas Hassanudin Makasar
Email : runalrezkiawan93@gmail.com

Abstract

Soft crab is an export product where foreign demand is much higher than production. In the production of soft crabs, it is done by keeping the crabs individually in a crab box which is placed in the pond until they molt. Molting is a natural process of molting, i.e. removing the old tough skin for growth purposes. Shortly after molting, the new crab shells are still very soft and will harden again after water absorption occurs. Therefore it is important to monitor molting crabs to help farmers in the cultivation of soft shell crabs. The number of crab datasets is 1060 which consists of 1000 training data and 60 testing data. There are several popular image classification algorithms, namely K-Nearest Neighbors (KNN), Support Vector Machine (SVM), and Random Forest Classifier (RFC). KNN, SVM, and RFC are classification algorithms from Machine Learning. This study aims to compare the performance of the three algorithms so that the performance of the three algorithms is known. Several parameters are used to configure the KNN, SVM, and RFC algorithms. From the results of the trials conducted, KNN has the best performance with 98.33% accuracy, 98.33% precision, 98.38% recall, and 98.38% F1 Score.

Keywords: Molting crab classification, Image Processing, Machine Learning, KNN, RFC, and SVM.

1. PENDAHULUAN

Kepiting bakau (*Scylla serrata* Forsskål, 1775) merupakan salah satu sumber daya hayati laut yang sebarannya sangat luas dan berlimpah di perairan Indonesia. Kepiting bakau merupakan salah satu jenis crustacea yang memiliki nilai ekonomis penting dan telah banyak dibudidayakan oleh petani tradisional untuk memenuhi kebutuhan pangan baik di pasar lokal maupun ekspor. Menurut BPS (2016) dinyatakan bahwa pasar ekspor kepiting ke beberapa negara, yaitu: Taiwan, China, Malaysia, Jepang, Amerika, Italy dan Singapore cukup besar. Jumlah ekspor Kepiting Bakau sebesar 109.624,4 ton pada tahun 2015 dan mengalami peningkatan per tahun sebesar 17,74% per tahun dari 58.091,8 ton pada tahun 2010 [1].

Salah satu teknologi budidaya kepiting yang membutuhkan waktu relatif cepat dan mortalitas yang rendah adalah budidaya kepiting cangkang lunak [2]. Kepiting lunak (soft shell crab) adalah salah satu makanan laut (seafood) di dunia yang terkenal karena kelezatannya.

Produk ini belum dikenal luas oleh masyarakat Indonesia meskipun banyak diproduksi di Indonesia. Hal ini terjadi karena kepiting lunak adalah produk ekspor yang mana permintaan luar negeri jauh lebih tinggi dibanding produksi. Komoditas ini diekspor ke Amerika, Cina, Jepang, Hongkong, Korea Selatan, Taiwan, Malaysia, dan sejumlah negara di kawasan Eropa. Produksi kepiting lunak dilakukan dengan memelihara kepiting secara individu dalam kotak (crabs box) yang ditempatkan di dalam tambak hingga molting. Molting adalah proses pergantian kulit secara alami, yakni melepaskan kulit lama yang keras untuk tujuan pertumbuhan. Sesaat setelah molting, kulit kepiting yang baru masih dalam kondisi sangat lunak dan akan mengeras kembali beberapa jam kemudian setelah terjadi penyerapan air. Kepiting dengan kondisi lunak inilah yang dipanen sebagai kepiting lunak [3].

Agar panen kepiting lunak dapat dilakukan lebih cepat maka ada beberapa perlakuan yang dapat diberikan yaitu salah satunya melalui teknik mutilasi, yakni dengan sengaja

menanggalkan kaki-kaki kepiting untuk merangsang molting. Menurut Raden Ariodkk, dalam penelitiannya tentang Perbedaan Metode Mutilasi Terhadap Lama Waktu Molting Scylla serrata menunjukkan berpengaruh terhadap lama waktumolting dan menggunakan teknik tersebut, tidak berpengaruh terhadap pertumbuhan berat mutlak [4].

Dalam budidaya kepiting lunak, Dalam budidaya kepiting lunak, pengawasan sangat menentukan kualitas kepiting lunak yang berhasil. Hal tersebut dikarenakan kepiting yang dipanen sesaat setelah molting. Bila kepiting terlambat dipanen, maka kulit mereka segera mengeras kembali dan hal ini menyebabkan kualitas menurun [5]. Penelitian diatas membuktikan bahwa pentingnya pemantauan terhadap kepiting molting dalam budidaya kepiting cangkang lunak dengan menggunakan teknologi klasifikasi Machine Learning untuk deteksi lebih dini agar lebih cepat di tangani ketika kepiting lunak. Oleh

karena itu, penelitian ini mengusulkan sistem deteksi klasifikasi kepiting molting untuk memberikan kemudahan kepada pembudidaya dalam pemantauannya.

2. METODE PENELITIAN

Metodologi penelitian yang dilakukan terdiri dari pengumpulan dataset dan pra-pemrosesan, deteksi objek dan klasifikasi, dan perhitungan performa. Gambar 1 menunjukkan alur metodologi penelitian. pada pengumpulan dataset dilakukan beberapa proses yakni pembagian data training dan data testing terhadap citra kepiting molting dan non-molting, setelah itu dilakukan pra proses pada dataset training dan testing. setelah dilakukan pra-pemrosesan pola pada data training kemudian di simpan untuk selanjutnya melakukan proses klasifikasi terhadap data testing. Selanjutnya melakukan evaluasi performa pada beberapa jenis klasifikasi dan parameter yang digunakan.

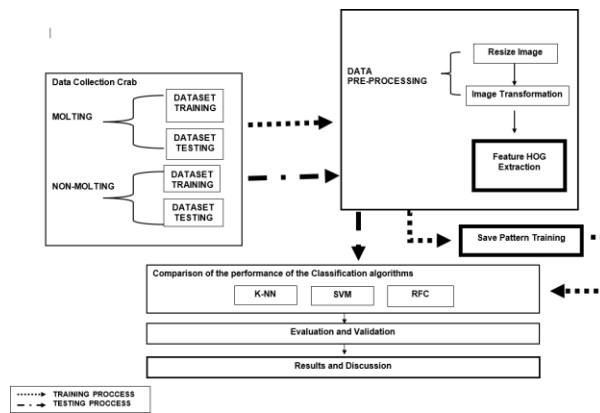


Fig. 1. Alur metodologi penelitian

A. Data Collection and Pre-Processing

Dataset yang digunakan dalam penelitian ini adalah citra kepiting yang terdiri dari 2 kelas yakni kelas molting dan non-molting. Terlihat pada gambar 2 Citra kepiting non- molting merupakan kepiting

yang telah di mutilasi kakinya yang di gunakan petambak dalam memanen kepiting molting sedangkan pada gambar 3 menunjukkan citra kepiting molting. Dataset yang digunakan berdimensi ukuran 960x720 sebelum dilakukan training.



Fig. 2. Non-Molting



Fig. 3. Molting

1) Data Collection

Pada tahapan ini dilakukan pembagian terhadap dataset citra kepiting. Sebelum melakukan training citra, dataset dibagi menjadi 2 kelas yakni kepiting molting dan non-molting. Dari total citra kepiting 1060 kemudian dibagi menjadi 2 kelas yakni 530 dataset molting dan 530 non-molting, dengan rincian 500 data citra untuk training dan 30 data citra untuk testing pada kepiting molting dan untuk kepiting non-molting dengan rincian 500 data citra untuk training dan 30 data citra untuk testing. Peneliti menggunakan Bahasa Pemrograman Python dan Anaconda Navigator sebagai aplikasi GUI dan Jupyter Notebook sebagai text editor. kemudian melihat performa matrix tiap klasifikasi yang digunakan. Training algoritma KNN dilakukan menggunakan parameter yang dijelaskan pada Tabel 1. Begitu pula untuk algoritma SVM dan RFC training

dilakukan masing-masing menggunakan parameter seperti pada Tabel 2 dan 3.

2) Data Pre-Processing

Setelah dilakukan pembagian terhadap dataset citra, selanjutnya melakukan pra-pemrosesan terhadap dataset. Ada beberapa hal dalam tahap pra-pemrosesan data yaitu Resize Image, Image Transformation dan ekstraksi fitur HOG.

a) Resize Image

Tahap awal pra-pemrosesan data adalah resize image. Resize image diperlukan untuk menyamakan citra yang didapat sehingga mempermudah pengolahan tanpa menghilangkan kualitas citra [11] [12]. Resize image menggunakan package cv2 yang tersedia pada Open CV package. Ukuran yang diset adalah 72 x 72 pixel. Pada gambar 4 dan 5 merupakan data citra yang sebelum resize dan setelah resize




Fig. 4. data citra molting yang sebelum resize dan setelah resize

b) Image Transformation




Fig. 5. data citra non-molting yang sebelum resize dan setelah resize

Tahap selanjutnya adalah transformasi citra. Citra yang telah diresize akan dirubah warnanya menjadi grayscale. Hal ini dilakukan agar nilai piksel yang akan diambil tidak terlalu luas [13]. Sehingga citra yang ditransformasi menjadi warna greyscale hanya memiliki rentang piksel dari 0 ke 1, 0 sebagai warna

putih, 1 sebagai warna hitam, dan nilai diantaranya adalah warna abu. Setelah menjadi citra grayscale akan diambil nilai piksel dari warna tersebut. Gambar 6 dan 7 adalah gambar yang belum ditransformasi dan yang telah ditransformasi ke greyscale.




Fig. 6. data citra molting yang belum ditransformasi dan yang telah ditrans-formasi ke




Fig. 7. data citra non-molting yang belum ditransformasi dan yang telahditransformasi ke greyscale

c) Feature HOG Extraction

Pada tahapan ini dilakukan

ekstraksi fitur HOG citra latih dan citra uji. Pada proses ini, sebelumnya telah dilakukan resize yang berukuran 72 x 72 pixel. Setelah melakukan resize data sebanyak 1060 citra, kemudian citra keping molting dan non molting pada data latih dan data uji diubah ke citra grayscale. HOG merupakan bentuk dari local objek dan nilai yang digunakan dari intensitas gradien untuk mengekstraksi fitur yang digunakan pada computer vision dan image processing. HOG memiliki keunggulan, yaitu mampu menangkap tepi atau struktur gradient yang sangat karakteristik dari bentuk sebenarnya [14]. Tiap image mempunyai karakteristik yang ditunjukkan oleh distribusi gradient. Karakteristik tersebut diperoleh dengan membagi image ke dalam daerah kecil yang disebut cell. Langkah-langkah metode HOG adalah sebagai berikut:

- Melakukan normalisasi warna pada citra
- Menghitung gradien citra
- Melakukan spatial dan orientation binning
- Melakukan normalisasi dan membentuk descriptor block

B. *object Detection with Classification Algorithm*

Objek yang akan dideteksi terdiri dari 2 kategori yaitu keping molting dan non-

molting. Proses klasifikasi objek menggunakan teknologi machine learning dengan algoritma k- nearest neighbors (kNN), random forest classifier (RFC) dan support vector machine (SVM) dengan bantuan pemrograman python. Pada tahapan proses klasifikasi, dilakukan proses training citra. Dalam prosesnya ada beberapa parameter yang menjadi model pada tiap jenis klasifikasi yang digunakan.

1) Klasifikasi

Klasifikasi merupakan suatu proses pengkategorian yang dilakukan terhadap sekumpulan data. Klasifikasi diawali dengan membagi koleksi data menjadi dua bagian utama yaitu data latih dan data uji. Dari data latih di hitung dengan menggunakan metode tertentu kemudian, diperoleh model klasifikasi yang nantinya akan digunakan untuk penentuan kelas terhadap data uji [15]. Terdapat beberapa algoritma klasifikasi yang digunakan yaitu.

a) K-Nearest Neighbors (kNN)

KNN merupakan algoritma yang bekerja dengan mengelompokkan data berdasarkan nilai yang berdekatan dengan data tersebut [16]. Perhitungan jarak antara data dengan kelompok menggunakan perhitungan jarak euclidian dan jarak Minkowski. Jarak euclidian didapat berdasarkan perhitungan pada persamaan 2 berikut ini [17].

- Distance Euclidian function:

$$d(a, b) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (1)$$

- Distance Minkowski function:

$$d(a, b) = \sqrt[p]{(x_1 - x_2)^p + (y_1 - y_2)^p} \quad (2)$$

b) Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan sebuah metode yang bersifat supervised, Support Vector Machine dapat digunakan untuk membuat sebuah model dari hasil analisa data baik untuk kasus klasifikasi maupun regresi [18]. Support Vector Machine bekerja dengan mencari titik terluar dari masing-masing data untuk kemudian ditarik sebuah garis pemisah yang paling optimal [19]. Dari garis pemisah yang telah didapat maka akan terdapat dua atau lebih kelompok data. Support Vector

Machine dapat melakukan baik itu linear dan non-linear klasifikasi. Gambar 8 merupakan ilustrasi dari metode Support Vector Machine

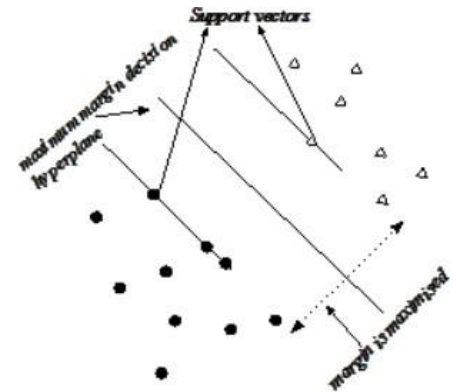


Fig. 8. ilustrasi metode SVM

Pada metode SVM, titik terluar dari masing-masing kelompok data akan dicari. Setelah titik terluar data ditemukan maka akan dihitung margin antar titik untuk kemudian ditarik garis pemisah antar kelompok data. Hal tersebut akan terus diulang hingga ditemukan garis pemisah terbaik untuk memisahkan masing-masing kelompok data.

c) Forest Classifier (RFC)

Random forest merupakan sebuah integrasi dari bagging dan beberapa Decision Tree [20]. Beberapa kombinasi tree akan menghasilkan beberapa suara yang kemudian diambil suara terbanyak atau voting. Hasil voting ini lah yang menjadi hasil akhir dari klasifikasi. Ilustrasi dari metode Random Forest dapat dilihat pada gambar 9. Pada

gambar5 Random Forest merupakan kumpulan dari Tree 1, Tree 2, ..., Tree b setiap tree akan menghasilkan sebuah keputusan. Dari setiap keputusan yang di- hasilkan akan dilakukan voting, k merupakan hasil voting dari seluruh tree yang ada di dalam RandomForest.

2) Pembentukan Model Klasifikasi

Pada tahapan ini setiap algoritma dikonfigurasi menggunakan beberapa parameter. Tujuannya adalah un- tuk mengetahui pengaruh parameter terhadap performa yang dihasilkan. Pada algortima KNN parameter yang diujicobakan adalah tipe distance dan jumlah neighbors. Tabel 1 menunjukkan parameter dari KNN yang di- gunakan dalam penelitian ini. Jumlah neighbors yang digunakan adalah 1, 7, dan 9, sedangkan tipe distance yang digunakan adalah Euclidean [21] dan Minkowski




Fig. 9. ilustrasi metode RFC

[22].

Tabel 1. Parameter KNN

Parameter	Deskripsi
Jumlah Neighbors	1, 7, 9
Tipe Distance	Euclidean, Minkowski

Pada algoritma SVM parameter yang diujicobakan adalah jenis kernel. Tabel

2 menunjukkan parameter dari SVM.

Tabel 2. Parameter SVM

Parameter	Deskripsi
Kernel	Linear, Poly, RBF

Pada algoritma Random Forest Classifier (RFC) yang diujicobakan

adalah estimators yakni 20, 30, 40. Tabel 3 menunjukkan parameter dari random forest classifier (RFC).

Tabel 3. Parameter RFC

Parameter	Deskripsi
Estimato rs	20, 30, 40

Model klasifikasi yang dibentuk dalam penelitian ini dijalankan di sebuah perangkat keras komputer cloud dari

Google Colaboratory (Google Colab, 2020). Detail spesifikasi dari perangkat keras komputer yang digunakan dapat dilihat pada Tabel 4.

C. Perhitungan Performa

Pada tahapan ini dilakukan

perhitungan performa dari algoritma KNN, SVM, dan RFC. Performa yang dihitung adalah

Tabel 4. Spesifikasi Perangkat Keras Komputer

Parameter	Spesifikasi
CPU	Intel(R) Core(TM) i7-10870H CPU @ 2.20GHz 2.21 GHz
RAM	Intel(R) 16 GB
Space of Disk	500 GB
GPU Model Name	Nvidia GeForce RTX 2060 8GB

akurasi, precision, recall, dan F1 Score. Model pengujian tersebut dapat dibandingkan dengan hasil pada beberapa skenario yang dilakukan [23]. Presisi adalah rasio prediksi true positif dibandingkan dengan hasil prediksi positif secara keseluruhan. Recall adalah rasio true positif dibandingkan dengan semua data positif. f1-score adalah perbandingan presisi dan perolehan rata-rata tertimbang [24]. Confusion

Matrix memberikan perbandingan antara hasil klasifikasi yang dibuat oleh model dengan hasil klasifikasi yang sebenarnya. Akurasi adalah rasio true prediksi (positif dan negatif) terhadap keseluruhan data. Persamaan (3) (4) (5) (6) berturut turut menunjukkan rumus perhitungan akurasi, precision, recall, dan F1 Score. TP adalah True Positive, TN adalah True Negative, FP adalah FalsePositive, dan FN adalah False Negative.

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (3)$$

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

$$F1Score = \frac{Precision * Recall}{Precision + Recall} \quad (6)$$

3. HASIL DAN PEMBAHASAN

Tahap ini akan menjelaskan hasil evaluasi dari masing-masing metode yang digunakan pada penelitian ini. Evaluasi menjadi hal yang penting agar kita

mendapatkan sebuah metode yang cocok untuk mengklasifikasi citra kepiting molting. Hasil yang akan dibahas adalah tingkat akurasi masing-masing metode, nilai presisi, recall dan F1 Score.

A. KNN

Tabel 5 menunjukkan hasil performa dari algoritma KNN. NN adalah Number Neighbors (Jumlah Neighbors), matrix adalah parameter penghitung jarak. Nilai yang di ambil adalah AVG atau rata-rata performa dari tiap kelas. Berdasarkan perhitungan performa yang dilakukan, algo ritma KNN dengan distance

Minkowski dan Euclidean dengan jumlah neighbors 1 memiliki performa terbaik. Perbedaan per- forma memang tidak signifikan, namun KKN dengan distance Minkowski dan Euclidean dengan jumlah neighbors 1 akan dibandingkan performanya dengan SVM dan RFC.

Tabel 5. Performa KNN

metric	N	Matrix			
		ACC	Prec	Recall	FI Score
Euclidean	1	98.33%	98.33%	98.38%	98.33%
Euclidean	7	96.66%	96.66%	96.87%	96.66%
Euclidean	9	95.0%	95.0%	95.05%	94.99%
Minkowski	1	98.33%	98.33%	98.38%	98.33%
Minkowski	7	96.66%	96.87%	96.66%	96.66%
Minkowski	9	95.0%	95.0%	95.05%	94.99%

B. SVM

Tabel 6 menunjukkan performa algoritma SVM. SVM dengan kernel Linear memiliki performa terbaik jika

dibandingkan dengan kernel lain. Semua metric performa dari kernel Linear mengungguli kernel yang lain. SVM dengan kernel Linear akan dibandingkan performanya dengan KNN dan RFC.

Tabel 6. Performa SVM

Kernel	Matrix			
	ACC	Prec	Recall	FI Score
Linear	96.66%	96.87%	96.66%	96.66%
Poly	83.33%	83.93%	83.33%	83.25%
RBF	83.33%	83.93%	83.33%	83.25%

D. Perbandingan Performa

Tabel 8 menunjukkan perbandingan performa antara algoritma KNN, SVM, dan RFC. Untuk algoritma KNN, penelitian ini memilih KNN dengan distance Minkowski dan Euclidean dengan jumlah neighbors 1 dikarenakan memiliki performa terbaik dibandingkan KNN dengan parameter neighbors 7 dan 9. Sedangkan untuk algoritma SVM, penelitian ini memilih SVM dengan kernel

LINEAR karena memiliki performa terbaik diantara SVM dengan parameter lain, begitu pula dengan RFC dengan estimators 30 memiliki performa terbaik diantara RFC dengan parameter lainnya. Gambar 10 menunjukkan grafik perbandingan performa antara algoritma KNN, SVM, dan RFC. Pada gambar 10 menunjukkan nilai akurasi tertinggi yaitu 98.33% dengan menggunakan algoritma KNN, dan selanjutnya.

Tabel 7 Perbandingan Performa

Algoritma ML	Matrix			
	ACC	Prec	Recall	F1 Score
K-NN Minkowski dan Euclidean 1	98.33%	98.33%	98.38%	98.33% [3]
SVM LINEAR	96.66%	96.87%	96.66%	96.66%
RFC Estimators 30	96.66%	96.66%	96.87%	96.66%




Fig. 10. Perbandingan performa algoritma KNN, SVM, dan RFC

akurasi untuk algoritma SVM dan RFC yakni 96.66%. Kemudian nilai presisi tertinggi yakni 98.33% dengan menggunakan algoritma KNN, dan selanjutnya nilai presisi untuk algoritma SVM yaitu 96.87% dan RFC 96.66%. Untuk nilai Recall tertinggi yakni 98.38% menggunakan algoritma KNN, lalu nilai 96.87% untuk RFC dan 98.38% untuk SVM. Kemudian untuk nilai F1 Score tertinggi yakni 98.33% menggunakan algoritma KNN, lalu nilai 96.66% untuk algoritma SVM dan RFC.

4. KESIMPULAN

Berdasarkan uji coba yang dilakukan penelitian ini, algoritma KNN memiliki performa terbaik dalam melakukan klasifikasi pada dataset kepiting molting dan non molting. Performa yang didapatkan oleh KNN adalah accuracy sebesar 98.33%, precision sebesar 98.33%, recall sebesar 98.38%, dan F1 score sebesar 98.33%, selanjutnya SVM dan RFC dengan akurasi dan F1 score yang sama yakni 96.66%, pada nilai recall SVM jauh sedikit lebih tinggi dari RFC yaitu dengan

salisih 0.21% sedangkan nilai precision jauh lebih unggul RFC dibanding dengan SVM yaitu dengan selisih 0.21%. Di masa depan, diharapkan pengklasifikasi KNN terhadap deteksi kepiting molting bisa di implementasikan dalam pembudidayaan kepiting cangkang lunak agar dapat memudahkan petambak dalam memonitoring kepiting molting dan berhasil panen.

DAFTAR PUSTAKA

- [1] BPS, Data Produksi Kepiting Bakau. Jakarta, 2016.
- [2] H. Kudsiah, S. W. Rahim, M. A. Rifa'i, and Arwan, "Demplot Pengembangan Budidaya Kepiting Cangkang Lunak Di Desa Salemba, Kecamatan Ujung Loi, Kabupaten Bulukumba Sulawesi Selatan," J. Panrita Abdi Univ. Hasanuddin, vol. 2, no. 2, pp. 151–164, 2018, [Online]. Available: <https://journal.unhas.ac.id/index.php/panritaabdi/issue/view/518>.
- [3] Y. Fujaya, "Pertumbuhan dan molting kepiting bakau yang diberi dosis vitomolot

- berbeda Growth and molting of mud crab administered by different doses of vitomolt,” *J. Indones. Aquac.*, vol. 10, no. 1, pp. 24–28, 2011.
- [4] R. Ario, A. Djunaedi, I. Pratikto, P. Subardjo, and F. Farida, “Perbedaan Metode Mutilasi Terhadap Lama Waktu Molting Scylla serrata,” *Bul. Oseanografi Mar.*, vol. 8, no. 2, p. 103, 2019, doi: 10.14710/buloma.v8i2.24886.
- [5] N. A. Yushinta Fujaya, Siti Aslamyah, Letty Fudjaja, Budidaya dan Bisnis Kepiting Lunak: Stimulasi Molting Dengan Ekstrak Bayam. Surabaya: Firstbox Media, 2019.
- [6] F. F. Ferdiansyah, B. Rahmat, and I. Yuniar, “Klasifikasi Dan Pengenalan Objek Ikan Menggunakan Algoritma Support Vector Machine (Svm),” *J. Inform. dan Sist. Inf. (JIFoSI)*, vol. 1, no. 2, pp. 522–528, 2020.
- [7] M. Ramadhani and D. H. Murti, “Klasifikasi Ikan Menggunakan Oriented Fast and Rotated Brief (Orb) Dan K-Nearest Neighbor (Knn),” *JUTI J. Ilm. Teknol. Inf.*, vol. 16, no. 2, p. 115, 2018, doi: 10.12962/j24068535.v16i2.a711.
- [8] M. M. M. Fouad, H. M. Zawbaa, N. El-Bendary, and A. E. Hassanien, “Automatic Nile Tilapia fish classification approach using machine learning techniques,” *13th Int. Conf. Hybrid Intell. Syst. HIS 2013*, pp. 173–178, 2014, doi: 10.1109/HIS.2013.6920477.
- [9] L.-D. Quach, L. Q. Hoang, N. D. Trung, and C. N. Nguyen, “Towards Machine Learning Approaches To Identify Shrimp Diseases Based on Description,” 2020, doi: 10.15625/vap.2019.00063.
- [10] R. Ali, M. M. Yusro, M. S. Hitam, and M. Ikhwanuddin, “Machine Learning With Multistage Classifiers For Identification Of Ectoparasite Infected Mud Crab Genus Scylla,” *Telkomnika (Telecommunication Comput. Electron. Control.*, vol. 19, no. 2, pp. 406–413, 2021, doi: 10.12928/TELKOMNIKA.v19i2.16724.
- [11] D. Abdullah and E. D. Putra, “Komparasi Perbaikan Kualitas Segmentasi Pada Citra Digital Metode Fuzzy C-Means Dan Otsu,” *Pseudocode*, vol. 4, no. 1, pp. 71–80, 2017.
- [12] D. S. Tobias and A. R. Widiarti, “Deteksi Glaukoma pada Citra Fundus Retina dengan Metode K-Nearest Neighbor,” in *Seminar Nasional Ilmu Komputer(SNIK 2016)*, 2016, pp. 92–99.
- [13] F. Muwardi and A. Fadlil, “Sistem Pengenalan Bunga Berbasis Pengolahan Citra dan Pengklasifikasi Jarak,” *J. Ilm. Tek. Elektro Komput. dan Inform.*, vol. 3, no. 2, pp. 124–131, 2017.
- [14] N. Dalal and B. Triggs, “Histograms of Oriented Gradients for Human Detection,” in *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR’05)*, 2005, vol. 1, pp. 886–893.
- [15] E. F. Saraswita, “Akurasi Klasifikasi Citra Digital Scenes RGB Menggunakan Model K-Nearest Neighbor dan Naive Bayes,” *Pros. Annu. Res. Semin.*, vol. 5, no. 1, pp. 978–979, 2019.
- [16] Mustakim and G. Oktaviani F, “Algoritma K-Nearest Neighbor Classification Sebagai Sistem Prediksi Predikat Prestasi Mahasiswa,” vol. 13, no. 2, pp. 195–202, 2016.
- [17] A. Pandey and A. Jain, “Comparative Analysis of KNN Algorithm using Various Normalization Techniques,” *Int. J. Comput. Netw. Inf. Secur.*, vol. 9, no. 11, pp. 36–42, 2017.
- [18] E. Ahishakiye, E. O. Omulo, D. Taremwa, and I. Niyonzima, “Crime prediction using Decision Tree (J48) classification algorithm,” *Int. J. Comput. Inf. Technol.*, vol. 06, no. 03, pp. 188–195, 2017.
- [19] T. B. Sasongko, “Komparasi dan Analisis Kinerja Model Algoritma SVM dan PSO-

- SVM (Studi Kasus Klasifikasi Jalur Minat SMA),” *J. Tek. Inform. dan Sist. Inf.*, vol. 2, no. 2, pp. 244–253, 2016.
- [20] Y. Xu, X. Zhao, Y. Chen, and Z. Yang, “Research on a mixed gas classification algorithm based on extreme random tree,” *Appl. Sci.*, vol. 9, no. 9, 2019.
- [21] DOKMANIC, I., PARHIZKAR, R., RANIERI, J. AND VETTERLI, M., 2015. Euclidean Distance Matrices: Essential Theory, Algorithms and Applications. *IEEE Signal Processing Magazine*, [online] 32(6), pp.12–30. Available at: <http://arxiv.org/abs/1502.07541>; [Accessed 29 Dec. 2020].
- [22] OLAKOĞ LU, H.B., 2019. A generalization of the Minkowski distance and a new definition of the ellipse. [online] Available at: <http://arxiv.org/abs/1903.09657>; [Accessed 29 Dec. 2020].
- [23] Sari, V., Firdausi, F., & Azhar, Y. (2020). Perbandinga Prediksi Kualitas Kopi Arabika dengan Menggunakan Algoritma SGD, Random Forest dan Naive Bayes. *Edumatic: Jurnal Pendidikan Informatika*, 4(2), 1–9. <https://doi.org/10.29408/edumatic.v4i2.2202>.
- [24] Patil, N. M., & Nemade, M. U. (2017). Music Genre Classification Using MFCC , K-NN and SVM Classifier. *International Journal of Computer Applications*, 4(2), 43–47
- [22], OLAKOĞ LU, H.B., 2019. A