



ISSN : 2339 - 1871

JURNAL ILMIAH BETRIK

Besemah Teknologi Informasi dan Komputer

Editor Office : LPPM Sekolah Tinggi Teknologi Pagar Alam, Jln. Masik Siagim No. 75
Simpang Mbacang, Pagar Alam, SUM-SEL, Indonesia
Phone : +62 852-7901-1390.
Email : betrik@sttpagaralam.ac.id | admin.jurnal@sttpagaralam.ac.id
Website : <https://ejournal.sttpagaralam.ac.id/index.php/betrik/index>

KLASIFIKASI MAMALIA MENGGUNAKAN EXTREME GRADIENT BOOSTING BERDASARKAN FITUR HISTOGRAM OF ORIENTED GRADIENT

Yohannes¹, Johannes Petrus²

Program Studi Informatika Universitas Multi Data Palembang^{1,2}

Jalan Rajawali No. 14 Palembang

Sur-el : yohannesmasterous@mdp.ac.id¹, johannes@mdp.ac.id²

Abstrak: Mamalia merupakan salah satu jenis hewan yang memiliki banyak ciri dan karakteristik. Bentuk wajah pada setiap jenis hewan mamalia mempunyai bentuk yang mirip. Wajah hewan mamalia dalam bentuk citra gambar tampak depan menjadi tantangan dalam klasifikasi citra. Pada penelitian ini, *Histogram of Oriented Gradient* (HOG) digunakan sebagai fitur bentuk wajah hewan mamalia. HOG digunakan sebagai fitur penguat dalam proses klasifikasi menggunakan metode *eXtreme Gradient Boosting* (XGBoost). Pengujian dilakukan menggunakan dataset citra wajah tampak depan hewan mamalia yang terdiri dari 15 jenis. Hasil dari pengujian menunjukkan bahwa metode XGBoost dengan fitur HOG mampu memberikan hasil klasifikasi hewan mamalia yang lebih baik daripada tanpa menggunakan fitur HOG. Hal ini ditunjukkan dengan peningkatan nilai *precision* sebesar 0,61; *recall* sebesar 0,62; dan *f1-score* 0,60 pada XGBoost dengan fitur HOG yang hampir dua kali lipat daripada XGBoost tanpa fitur HOG.

Kunci Utama: *eXtreme Gradient Boosting, Histogram of Oriented Gradient, Mamalia*

Abstract: *Mammals are one type of animal that has many characteristics and characteristics. The shape of the face in each type of mammal has a similar shape. The faces of mammals in the form of frontal images are a challenge in image classification. In this study, the Histogram of Oriented Gradient (HOG) is used as a feature of the facial shape of mammals. HOG is used as a strengthening feature in the classification process using the eXtreme Gradient Boosting (XGBoost) method. The test was carried out using a dataset of frontal facial imagery of mammals consisting of 15 species. The results of the tests show that the XGBoost method with the HOG feature is able to provide better classification results for mammals than without the HOG feature. This is indicated by an increase in the precision value of 0.61; recall of 0.62; and an f1-score of 0.60 on XGBoost with HOG feature which is almost double that of XGBoost without HOG feature.*

Keywords : *eXtreme Gradient Boosting, Histogram of Oriented Gradient, Mammal*

1. PENDAHULUAN

Mamalia adalah vertebrata dan biasanya bereproduksi melalui kelahiran. Mamalia memiliki banyak ciri dan

karakteristik yang membuat sulit untuk membedakan antara spesies mamalia. Beberapa ciri mamalia dapat digunakan sebagai ciri pembeda dalam klasifikasi.

Citra jejak kaki yang merepresentasikan jumlah dan ukuran lipatan tapak telah digunakan sebagai fitur dalam klasifikasi spesies hewan [1]. Jejak kaki tidak hanya dapat hadir saat mengklasifikasikan hewan, tetapi gambar wajah hewan saat melihat ke depan juga dapat menjadi fitur penting. Tampak depan citra wajah hewan merupakan fitur klasifikasi pilihan karena dapat langsung merepresentasikan hewan tersebut. Pada penelitian [2], [3], [4], [5] citra wajah hewan digunakan sebagai karakteristik untuk klasifikasi hewan.

Pada penelitian [2], klasifikasi hewan dilakukan berdasarkan citra wajah menggunakan metode *Convolutional Neural Network*. *Kernel Fisher Analysis* digunakan sebagai ekstraksi ciri dengan pendekatan *score-level fusion*. Metode ini dapat digunakan untuk mengklasifikasikan mamalia berdasarkan fitur wajah [2]. Fitur wajah juga telah digunakan sebagai ciri untuk klasifikasi wajah manusia menggunakan LDA dan KNN [6]. Metode *Convolutional Neural Network* unggul dalam deteksi, prediksi, dan klasifikasi namun memiliki kelemahan, yaitu membutuhkan data pelatihan dalam jumlah besar, proses pelatihan yang memakan waktu yang lama, dan *overfitting*.

Boosting merupakan teknik pembelajaran *ensemble* untuk membangun *classifier* yang kuat dari beberapa *classifier* yang lemah secara seri. Algoritma *Boosting* memainkan peran penting dalam menangani pertukaran *bias* dan *variance*. Tidak seperti algoritma *bagging* yang hanya mengontrol *variance* tinggi dalam suatu model, *boosting* mengontrol kedua aspek, yaitu *bias* dan *variance* yang dianggap lebih efektif [7].

Gradient Boosting adalah teknik pembelajaran mesin yang digunakan untuk melakukan regresi dan klasifikasi. Model prediksi oleh *Gradient Boosting* dihasilkan dalam bentuk *ensemble* dari *weak prediction* model, yang biasanya merupakan pohon keputusan [7]. *Gradient boosting* dapat dijelaskan dengan paling mudah dengan terlebih dahulu memperkenalkan algoritma *AdaBoost*.

Algoritma *AdaBoost* dimulai dengan melatih pohon keputusan di mana setiap pengamatan diberi bobot yang sama. Setelah mengevaluasi pohon pertama, dilanjutkan dengan menambah bobot pengamatan yang sulit diklasifikasikan dan menurunkan bobot pengamatan yang mudah diklasifikasikan. Oleh karena itu, pohon kedua ditanam pada data berbobot ini. Di sini, idenya adalah memperbaiki prediksi dari pohon pertama. Oleh karena itu, model baru tersebut adalah Pohon 1 + Pohon 2. Kemudian menghitung kesalahan klasifikasi dari model *ensemble* 2 pohon baru ini dan menumbuhkan pohon ketiga untuk memprediksi residu yang direvisi. Metode ini akan mengulangi proses ini untuk sejumlah iterasi tertentu. Pohon berikutnya akan membantu untuk mengklasifikasikan pengamatan yang tidak diklasifikasikan dengan baik oleh pohon sebelumnya. Prediksi dari model *ensemble* akhir adalah penjumlahan terbobot dari prediksi yang dibuat oleh model pohon sebelumnya [7].

Gradient Boosting melatih banyak model secara bertahap, aditif, dan berurutan. Perbedaan utama antara *AdaBoost* dan *Gradient Boosting* adalah bagaimana kedua algoritma tersebut mengidentifikasi kekurangan pembelajar yang lemah [7]. Sementara model

AdaBoost mengidentifikasi kekurangan dengan menggunakan titik data berbobot tinggi, *Gradient Boosting* melakukan hal yang sama dengan menggunakan gradien dalam *loss function* ($y = ax + b + e$), dimana e perlu disebutkan secara khusus karena merupakan istilah *error*). *Loss function* adalah ukuran yang menunjukkan seberapa baik koefisien model sesuai dengan data yang mendasarinya. Pemahaman logis tentang *loss function* akan bergantung pada apa yang dioptimalkan [8].

XGBoost adalah algoritma pembelajaran mesin *ensemble* berbasis pohon keputusan yang menggunakan kerangka kerja *gradient boosting*. *XGBoost* merupakan metode yang beradaptasi dengan baik untuk semua jenis data dan masalah. *XGBoost* dan *gradient boosting*, keduanya merupakan metode pohon *ensemble* yang menerapkan prinsip meningkatkan *weak learner* (umumnya CART) menggunakan arsitektur penurunan gradien. Namun, *XGBoost* meningkatkan kerangka kerja *gradient boosting* dasar melalui pengoptimalan sistem dan peningkatan algoritmik [9].

Histogram of Oriented Gradient (HOG) adalah metode ekstraksi fitur bentuk yang mampu digunakan sebagai fitur dalam klasifikasi objek. Fitur HOG ini tergolong kuat dibandingkan dengan fitur lokal lainnya [2]. HOG telah banyak digunakan sebagai fitur unggul dalam mengenal bentuk objek dalam sebuah citra. HOG dapat menjadi fitur untuk pengenalan manusia dan lebih baik dari *Gaussian Mixture Model* [10]. HOG juga telah digunakan untuk mengidentifikasi plat nomor kendaraan dengan akurasi tinggi [11]. Pada klasifikasi jenis buah dan sayuran, HOG mampu menjadi fitur

bentuk yang sangat baik yang berbasis *saliency* [12]. Dalam hal klasifikasi hewan mamalia, HOG mampu menjadi fitur bentuk wajah dari sebuah citra [4], [13], [3]. Selain itu, HOG juga menjadi fitur penguat untuk metode klasifikasi *XGBoost* dalam hal klasifikasi pada studi kasus deteksi pedestrian [14].

Melihat HOG mampu menjadi peran fitur yang sinergi terhadap peningkatan metode *XGBoost* dalam hal klasifikasi, maka dilakukan klasifikasi jenis hewan mamalia berdasarkan citra wajah hewan tampak depan menggunakan *XGBoost* dengan fitur HOG.

2. METODE PENELITIAN

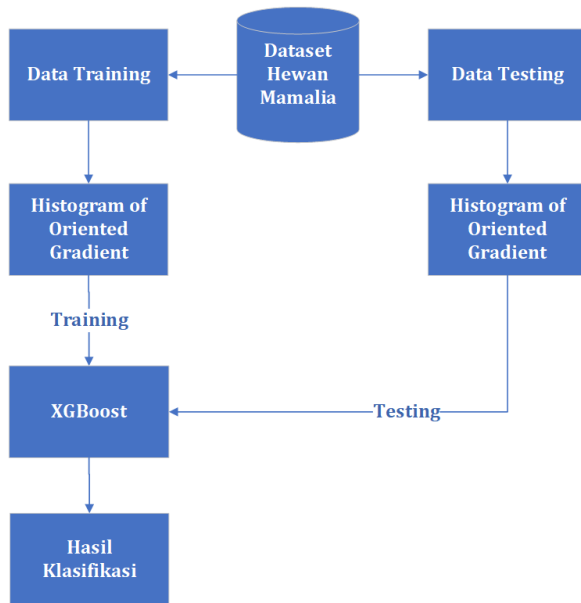
Dataset yang digunakan dalam penelitian ini adalah *LHI-Animal-Faces* [15]. Dataset ini terdiri dari data citra hewan dari 15 spesies mamalia yang masing-masing terdiri dari 60 citra dengan ukuran 150 x 150 piksel [13]. Tampilan depan wajah hewan mamalia dalam dataset ditunjukkan pada Gambar 1.



Gambar 1. Citra Hewan Mamalia [15]

Langkah-langkah yang dilakukan dalam penelitian ini dimulai dengan membagi dataset mamalia menjadi data latih dan data uji. Setiap data latih dan data uji yang digunakan terdiri dari 50 citra dan 10 citra hewan mamalia. Setiap citra dari data pelatihan dan pengujian dilakukan ekstraksi fitur menggunakan *histogram of oriented gradient* (HOG) untuk menangkap fitur bentuk wajah hewan mamalia dalam sebuah citra. Fitur

yang dibuat dari data latih dan uji digunakan dalam proses klasifikasi menurut metode *XGBoost*. Secara umum, langkah-langkah metode yang diusulkan dalam penelitian ini ditunjukkan pada Gambar 2.



Gambar 2. Metode yang diusulkan

2.1 Histogram of Oriented Gradient (HOG)

HOG adalah nilai representasi bentuk dari objek lokal yang digunakan untuk mengekstraksi fitur dari intensitas gradien pada sebuah citra gambar. HOG memiliki kelebihan, yaitu dapat menangkap tepi atau gradien yang sangat khas dari bentuk sebenarnya [16]. Tiap gambar memiliki properti yang ditunjukkan oleh distribusi gradien. Fitur ini diperoleh dengan membagi citra menjadi area-area yang kecil. Tahapan HOG dapat dilihat pada Gambar 3.



Gambar 3. Tahapan Metode HOG

2.2 Extreme Gradient Boosting (XGBoost)

Algoritma *Gradient Boosting* tradisional hanya menggunakan informasi turunan orde pertama. Selain itu, karena ketergantungan antara pembelajar yang lemah (*weak learner*), *Gradient Boosting* sulit untuk melatih data secara paralel [17]. *XGBoost* mengambil ekspansi *Taylor* dari *loss function* hingga orde kedua dan menambahkan istilah regularisasi untuk menemukan solusi optimal, yang digunakan untuk menyeimbangkan penurunan fungsi tujuan dan kompleksitas model untuk menghindari *overfitting* [18]. Model *XGBoost* dapat direpresentasikan dengan Persamaan (1).

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in F \quad (1)$$

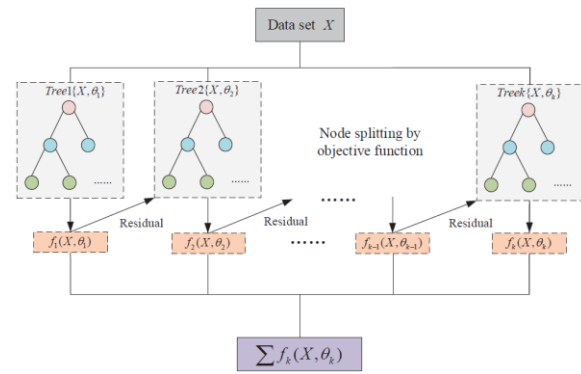
Pada Persamaan (1), K adalah jumlah pohon keputusan, $f_k(x_i)$ adalah fungsi input pada pohon keputusan ke- k , \hat{y}_i adalah nilai prediksi, dan F adalah himpunan dari semua CART yang mungkin. Fungsi tujuan *XGBoost* mencakup dua bagian, yaitu kesalahan pelatihan dan regularisasi yang dapat dilihat pada Persamaan (2).

$$X_{obj} = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (2)$$

Pada Persamaan (2), $\sum_{i=1}^n l(y_i, \hat{y}_i)$ digunakan untuk mengukur selisih antara nilai prediksi dan nilai sebenarnya dari *loss function*. $\sum_{k=1}^K \Omega(f_k)$ adalah suku regularisasi dan $\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \|\omega\|^2$. T adalah jumlah simpul daun (*number of leaf node*), ω adalah skor simpul daun (*scores of leaf node*), γ adalah koefisien penalti daun (*leaf penalty coefficient*), dan λ memastikan bahwa skor simpul daun tidak terlalu besar.

Algoritma *XGBoost* menggunakan strategi *gradient boosting*, menambahkan satu pohon baru sekaligus alih-alih mendapatkan semua pohon sekaligus, dan terus memperbaiki hasil pengujian sebelumnya dengan menyesuaikan sisa dari prediksi terakhir. Selama proses pelatihan, model terus menerus menghitung *node loss* untuk memilih *leaf node* dengan *gain loss* terbesar. *XGBoost* menambahkan pohon baru dengan terus membagi fitur. Menambahkan pohon setiap kali sebenarnya mempelajari fungsi baru $f_k(X, \theta_k)$ agar sesuai dengan sisa dari prediksi terakhir.

Ketika K pohon diperoleh setelah pelatihan, fitur sampel prediksi akan memiliki simpul daun yang sesuai di setiap pohon, dan setiap simpul daun sesuai dengan skor. Terakhir, skor yang sesuai dari setiap pohon dijumlahkan untuk mendapatkan nilai prediksi pengenalan dari sampel [19]. Diagram alir *XGBoost* ditunjukkan pada Gambar 4.



Gambar 4. Diagram alir *XGBoost*

2.3 Evaluasi Hasil Klasifikasi

Evaluasi hasil klasifikasi hewan mamalia menggunakan citra wajah tampak depan dilakukan untuk mengetahui performa klasifikasi dengan metode *XGBoost* dengan fitur HOG dan tanpa HOG. Alat ukur evaluasi yang digunakan pada penelitian ini adalah nilai *precision*, *recall*, dan *f1-score*. Nilai *precision*, *recall*, dan *f1-score* bergantung penuh dengan total nilai *true positive* (TP), *true negative* (TN), *false negative* (FN), dan *false positive* (FP). *Confusion matrix* dapat digunakan untuk membantu dalam menghitung nilai TP, TN, FN, dan FP. Nilai *precision*, *recall*, dan *f1-score* masing-masing dapat dihitung menggunakan Persamaan (3), (4), dan (5).

$$Precision = \frac{TP}{TP+FP} \tag{3}$$

$$Recall = \frac{TP}{TP+FN} \tag{4}$$

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{5}$$

Keterangan :

TP = Jumlah data positif citra objek wajah mamalia yang terklasifikasi dengan benar oleh sistem.

TN = Jumlah data negatif citra objek wajah mamalia yang terklasifikasi dengan benar oleh sistem.

FN = Jumlah data negatif citra objek wajah mamalia namun terklasifikasi salah oleh sistem.

FP = Jumlah data positif citra objek wajah mamalia namun terklasifikasi salah oleh sistem

3. HASIL DAN PEMBAHASAN

Pengujian pada klasifikasi hewan mamalia dengan citra wajah tampak depan menggunakan metode *XGBoost* dilakukan dengan dua skenario, yaitu tanpa menggunakan fitur HOG dan menggunakan fitur HOG. Hasil pengujian klasifikasi mamalia menggunakan *XGBoost* tanpa fitur HOG dapat dilihat pada Tabel 1. Hasil klasifikasi pada Tabel 1 menunjukkan bahwa wajah hewan mamalia belum dapat dikenali dengan baik hanya dengan citra RGB saja tanpa melibatkan fitur HOG. Hewan mamalia yang paling mudah dikenali tanpa fitur HOG pada Tabel 1 adalah Panda dengan nilai *precision* sebesar 1,00; *recall* sebesar 0,90; dan *f1-score* sebesar 0,95. Sebaliknya, untuk hewan mamalia yang paling tidak mudah dikenali tanpa fitur HOG adalah Kelinci dengan nilai *precision*, *recall*, dan *f1-score* sebesar 0.

Tabel 1. Hasil Klasifikasi Mamalia menggunakan XGBoost tanpa Fitur HOG

No	Kelas	Precision	Recall	F1-score
1	Beruang	0,40	0,60	0,48
2	Kucing	0,30	0,30	0,30
3	Sapi	0,42	0,50	0,45
4	Rusa	0,43	0,30	0,35
5	Anjing	0,17	0,20	0,18
6	Gajah	0,29	0,20	0,24
7	Singa	0,44	0,70	0,54
8	Monyet	0,50	0,10	0,17
9	Tikus	0,06	0,10	0,08

10	Panda	1,00	0,90	0,95
11	Babi	0,20	0,10	0,13
12	Kelinci	0,00	0,00	0,00
13	Domba	0,55	0,60	0,57
14	Harimau	0,33	0,40	0,36
15	Serigala	0,50	0,40	0,44

Hasil pengujian klasifikasi mamalia menggunakan *XGBoost* dengan fitur HOG dapat dilihat pada Tabel 2. Hasil klasifikasi pada Tabel 2 menunjukkan bahwa wajah hewan mamalia dapat dikenali dengan baik dengan melibatkan fitur HOG. Hewan mamalia yang paling mudah dikenali dengan fitur HOG pada Tabel 2 adalah Panda dengan nilai *precision* sebesar 0,91; *recall* sebesar 1,00; dan *f1-score* sebesar 0,95. Sebaliknya, untuk hewan mamalia yang paling tidak mudah dikenali dengan fitur HOG adalah Babi dengan nilai *precision*, *recall*, dan *f1-score* sebesar 0,10.

Tabel 2. Hasil Klasifikasi Mamalia menggunakan XGBoost dengan Fitur HOG

No	Kelas	Precision	Recall	F1-score
1	Beruang	0,88	0,70	0,78
2	Kucing	0,50	0,30	0,37
3	Sapi	0,50	0,90	0,64
4	Rusa	0,50	0,60	0,55
5	Anjing	0,80	0,80	0,80
6	Gajah	0,60	0,60	0,60
7	Singa	0,75	0,90	0,82
8	Monyet	0,50	0,50	0,50
9	Tikus	0,57	0,40	0,47
10	Panda	0,91	1,00	0,95
11	Babi	0,10	0,10	0,10
12	Kelinci	0,43	0,30	0,35
13	Domba	0,83	0,50	0,62
14	Harimau	0,71	1,00	0,83
15	Serigala	0,67	0,60	0,63

Tabel 3. Hasil Rata-Rata Keseluruhan Klasifikasi Mamalia

	<i>XGBoost</i>	<i>HOG-XGBoost</i>
<i>Precision</i>	0,37	0,62
<i>Recall</i>	0,36	0,61
<i>F1-score</i>	0,35	0,60

Secara keseluruhan metode klasifikasi *XGBoost* dengan fitur HOG mampu memberikan hasil klasifikasi lebih baik daripada *XGBoost* tanpa menggunakan fitur HOG. Hal ini dapat dilihat pada Tabel 3 yang menunjukkan bahwa terjadi peningkatan hasil klasifikasi mamalia dengan menggunakan fitur HOG baik dari nilai *precision*, *recall*, dan *f1-score*.

4. SIMPULAN

Berdasarkan hasil pengujian dapat disimpulkan bahwa metode fitur ekstraksi HOG mampu mengenali fitur wajah tampak depan pada citra hewan mamalia dengan baik. *XGBoost* sebagai metode klasifikasi yang digunakan pada penelitian ini mampu mengklasifikasi wajah hewan mamalia dengan nilai *precision*, *recall*, dan *f1-score* yang berbeda. Metode *XGBoost* dengan fitur HOG jauh lebih baik daripada tanpa menggunakan fitur HOG pada proses klasifikasi hewan mamalia. Hal ini ditunjukkan dengan peningkatan nilai *precision*, *recall*, dan *f1-score* pada *XGBoost* dengan fitur HOG yang hampir dua kali lipat daripada *XGBoost* tanpa fitur HOG. Jenis hewan mamalia yang paling mudah dikenali dengan baik adalah Panda. Sedangkan jenis hewan mamalia yang paling tidak mudah dikenali dengan baik adalah Babi.

DAFTAR RUJUKAN

- [1] M. N. Alli and S. Viriri, "Animal identification based on footprint recognition," *IEEE Int. Conf. Adapt. Sci. Technol. ICASST*, 2013, doi: 10.1109/ICASSTech.2013.6707488.
- [2] S. Taheri and Ö. Toygar, "Animal classification using facial images with score-level fusion," *IET Comput. Vis.*, vol. 12, no. 5, pp. 679–685, 2018, doi: 10.1049/iet-cvi.2017.0079.
- [3] M. E. Al Rivan and Y. Yohannes, "Klasifikasi Mamalia Berdasarkan Bentuk Wajah Dengan K-NN Menggunakan Fitur CAS Dan HOG," *J. Tek. Inform. dan Sist. Inf.*, vol. 5, no. 2, pp. 173–180, 2019.
- [4] Y. Yohannes, Y. P. Sari, and I. Feristyani, "Klasifikasi Wajah Hewan Mamalia Tampak Depan Menggunakan k-Nearest Neighbor Dengan Ekstraksi Fitur HOG," *J. Tek. Inform. dan Sist. Inf.*, vol. 5, no. 1, pp. 84–97, 2019, doi: 10.28932/jutisi.v5i1.1584.
- [5] Z. Cao, J. C. Principe, B. Ouyang, F. Dagleish, and A. Vuorenkoski, "Marine Animal Classification Using Combined CNN and Hand-designed Image Features," *Ocean. 2015 - MTS/IEEE Washingt.*, pp. 2–7, 2015.
- [6] F. Fandiansyah, J. Y. Sari, and I. P. Ningrum, "Pengenalan Wajah Menggunakan Metode Linear Discriminant Analysis Dan K Nearest Neighbor," *J. Inform.*, vol. 11, no. 2, pp. 48–59, 2017, doi: 10.26555/jifo.v11i2.a5998.
- [7] G. Kunapuli, *Ensemble Methods for Machine Learning Version 6*. The MathWorks, Inc., 2022.
- [8] T. C. Nokeri, *Data Science Solutions with Python*. 2022. [Online]. Available: <https://link.springer.com/10.1007/978-1-4842-7762-1>
- [9] G. Kyriakides and K. G. Margaritis, *Hands-On Ensemble Learning with Python*. 2019.
- [10] Y. F. Munawaroh and I. Salamah, "Analisa Perbandingan Algoritma Histogram of Oriented Gradient (HOG) dan Gaussian Mixture Model (GMM) Dalam Mendeteksi Manusia," *Semin. Nas. Inov. dan Apl. Teknol. Di Ind*. 2018, vol. 4, no. 2, pp. 251–255, 2018.
- [11] G. Ning, "Vehicle License Plate Detection and Recognition," University of Missouri, Columbia, 2013.
- [12] Y. Yohannes, M. R. Pribadi, and L. Chandra, "Klasifikasi Jenis Buah dan Sayuran Menggunakan SVM Dengan Fitur Saliency-HOG dan Color Moments," *Elkha*, vol. 12, no. 2, p. 125, 2020, doi: 10.26418/elkha.v12i2.42160.
- [13] Y. Yohannes and M. E. Al Rivan, "Penggunaan Global Contrast Saliency dan Histogram of Oriented Gradient

- Sebagai Fitur untuk Klasifikasi Jenis Hewan Mamalia,” *Petir*, vol. 13, no. 1, pp. 80–85, 2020, doi: 10.33322/petir.v13i1.908.
- [14] Y. Jiang, G. Tong, H. Yin, and N. Xiong, “A Pedestrian Detection Method Based on Genetic Algorithm for Optimize XGBoost Training Parameters,” *IEEE Access*, vol. 7, pp. 118310–118321, 2019, doi: 10.1109/ACCESS.2019.2936454.
- [15] Z. Si and S. Zhu, “Learning Hybrid Image Templates (HIT) by Information Projection,” *IEEE Trans. Pattern Anal. Mach. Intell.*, pp. 1354–1367, 2012.
- [16] 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. doi: 10.1109/CVPR.2005.177.
- [17] L. Wang, D. Zhou, H. Zhang, W. Zhang, and J. Chen, “Application of Relative Entropy and Gradient Boosting Decision Tree to Fault Prognosis in Electronic Circuits,” *Symmetry (Basel)*, vol. 10, no. 10, 2018, doi: 10.3390/sym10100495.
- [18] Y. Chen, X. Wang, Y. Jung, V. Abedi, R. Zand, M. Bikak, and M. Adibuzzaman, “Classification of short single-lead electrocardiograms (ECGs) for atrial fibrillation detection using piecewise linear spline and XGBoost,” *Physiol. Meas.*, vol. 39, no. 10, 2018, doi: 10.1088/1361-6579/aadf0f.
- [19] T. Chen and C. Guestrin, “XGBoost: A Scalable Tree Boosting System,” *Proc. 22nd ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, pp. 785–794, 2016, doi: 10.1145/2939672.2939785.
- [20] R. Guo, Z. Zhao, T. Wang, G. Liu, J. Zhao, and D. Gao, “Degradation State Recognition of Piston Pump Based on ICEEMDAN and XGBoost,” *Appl. Sci.*, vol. 10, no. 18, pp. 1–17, 2020, doi: 10.3390/app10186593.