

Klasifikas Sampah Menggunakan Metode Naive Bayes

Aqsa Almaaidah Alimun^a, Harlinda L^b, Huzain Azis^c

Universitas Muslim Indonesia, Makassar, Indonesia

Email: ^aitsmebbyal@gmail.com; ^bharlinda@umi.ac.id; ^chuzain.azis@umi.ac.id

Received: xx xx xxxx | Revised: xx xx xxxx | Accepted: xx xx xxxx | Published: xx xx xxxx

Abstrak

Pengelolaan sampah merupakan permasalahan serius yang dihadapi di Indonesia akibat tingginya laju produksi sampah dari konsumsi masyarakat, perkembangan industri, serta rendahnya sistem pengelolaan yang berwawasan lingkungan. Salah satu pendekatan yang dapat digunakan untuk membantu pengelolaan sampah adalah klasifikasi otomatis menggunakan metode pembelajaran mesin. Pada penelitian ini, dilakukan klasifikasi citra sampah menggunakan algoritma Naïve Bayes dengan dua pendekatan, yaitu Gaussian Naïve Bayes dan Multinomial Naïve Bayes. Dataset yang digunakan terdiri dari 997 citra yang terbagi dalam dua kelas, yaitu kertas dan karton. Proses penelitian meliputi preprocessing berupa *resize* citra ke ukuran 64×64 piksel, normalisasi, serta evaluasi model menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa Gaussian Naïve Bayes memberikan kinerja yang lebih baik dengan *accuracy* sebesar **79.50%**, sedangkan Multinomial Naïve Bayes hanya mencapai **59.50%**. Nilai evaluasi lainnya juga memperlihatkan tren serupa, di mana Gaussian Naïve Bayes lebih unggul dibandingkan Multinomial Naïve Bayes. Dengan demikian, dapat disimpulkan bahwa Gaussian Naïve Bayes lebih sesuai untuk klasifikasi citra sampah pada penelitian ini, dan berpotensi diterapkan dalam mendukung sistem pengelolaan sampah yang lebih efisien.

Kata kunci: Naïve Bayes, GaussianNB, MultinomialNB, Klasifikasi Citra Sampah

Pendahuluan

Sampah merupakan sisa barang atau makanan yang sudah tidak memiliki nilai gunanya [1]. Pertumbuhan penduduk dan pola konsumsi yang semakin meningkat menjadi faktor utama yang menyebabkan laju produksi sampah selalu terus bertambah. Selain itu, perkembangan industri dan teknologi juga berkontribusi terhadap peningkatan jumlah, volume, dan keragaman karakteristik sampah [2]. Sampah dapat diklasifikasikan menjadi sampah organik, sampah berbahaya, sampah elektronik, serta sampah konstruksi dan pembongkaran berdasarkan komposisinya serta potensi kesehatan lingkungan dan manusia [3],[4].

Plastik merupakan sampah material sintesis, organik, polimer, dan berbobot molekul tinggi. Menurut Organisasi Internasional untuk Standardisasi (ISO), plastik merupakan material yang mengandung polimer berbobot molekul tinggi sebagai bahan utamanya [5]. Persatuan Internasional Kimia Murni dan Terapan (IUPAC) mendefinisikan plastik sebagai material polimer yang mungkin mengandung zat lain untuk meningkatkan kinerja dan/atau mengurangi biaya. Plastik berbahan dasar fosil atau petrokimia memanfaatkan bahan baku fosil seperti minyak bumi dan gas alam. Sekitar 7% dari seluruh minyak bumi diubah menjadi plastik [6]. Contoh beberapa plastik berbahan dasar fosil yang paling umum digunakan adalah polietilena (PE), polipropilena (PP), polietilena tereftalat (PET), dan polistirena (PS). Sedangkan, plastik Berbasis Bio/Bioplastik adalah jenis plastik lainnya. Plastik ini didefinisikan sebagai plastik yang 100% karbonnya berasal dari pertanian, seperti pati jagung, jerami padi, protein kedelai dan selulosa, dan sumber daya kehutanan yang membuatnya dapat diperbarui [7].

Berdasarkan produk, dominasi sampah plastik terbanyak adalah plastik sachet makanan sebesar 25.733 sampah (www.mongabay.co.id). Hal ini membuat Indonesia menjadi negara penghasil sampah terbesar ke-5 di dunia pada 2020. Laporan Bank Dunia yang bertajuk The Atlas of Sustainable Development Goals 2023 menunjukkan bahwa Indonesia memproduksi sekitar 65,2 juta ton sampah [8].

Permasalahan utama pengelolaan sampah di Indonesia adalah tidak mengikuti pengelolaan yang berwawasan lingkungan [9]. Akibat pengelolaan sampah yang kurang optimal, pembakaran sampah sering terjadi di negara-negara berkembang. Sistem pengumpulan sampah yang tidak menentu dan tidak terpilah, serta kurangnya kesadaran masyarakat terhadap kesehatan lingkungan, menjadi pembakaran sampah yang merupakan cara

paling cepat dan mudah untuk membersihkan sampah [10]. Sehingga hal ini menjadi urgensi dalam penelitian. Peneliti tertarik untuk mengkaji lebih dalam terkait pengelolaan sampah berdasarkan klasifikasi sampah. Metode Naive Bayes dapat memberikan solusi yang efisien dan efektif dalam pengelolaan sampah, terutama dalam membedakan berbagai jenis sampah berdasarkan kategori tertentu seperti organik, anorganik, atau berbahaya.

Naive Bayes merupakan metode klasifikasi probabilistik sederhana. Metode ini akan menghitung sekumpulan probabilitas dengan menjumlahkan frekuensi dan kombinasi nilai dari kumpulan data tertentu [10],[11]. Keuntungan menggunakan metode Naive Bayes adalah hanya memerlukan sedikit data pelatihan untuk memperkirakan parameter (mean dan varians variabel) yang diperlukan untuk klasifikasi. Kelebihan menggunakan Naive Bayes adalah metode ini hanya memerlukan sejumlah kecil data pelatihan untuk menentukan estimasi parameter yang diperlukan dalam proses klasifikasi [12]. Naive Bayes sering kali bekerja lebih baik di sebagian besar situasi dunia nyata yang lebih kompleks dari yang diharapkan [13].

Penelitian [14] menyebutkan Naive Bayes berhasil mengklasifikasikan data 23 dari 25 data. Metode ini menunjukkan tingkat keberhasilan prediksi pelanggan sebesar 100% dari nilai precision, 91% untuk nilai recall dan nilai accuracy mencapai 92%. Penelitian Hayami [15] melakukan penelitian klasifikasi jamur menggunakan algoritma Naive Bayes. Penelitian ini menggunakan klasifikasi sebanyak empat kali dengan dua kali pembagian menggunakan categorical naive bayes dan dua kali menggunakan multinomial Naive Bayes untuk setiap porsi data set. Hasil ini menunjukkan akurasi 100% dengan 1 kesalahan prediksi kelas 0 pada model Categorical 2. Sementara itu, pada model Multinomial 1 dan Multinomial 2 diperoleh nilai akurasi sebesar 84% dan 85% [16]. Penelitian [16] mengkaji Implementasi Algoritma Naive Bayes untuk Klasifikasi Konten Twitter dengan Indikasi Depresi. Beberapa penelitian terdahulu sebelumnya masih ditemukan keterbatasan dalam mengkaji klasifikasi sampah menggunakan metode Naive Bayes. Sehingga hadirnya penelitian ini menjadi penting untuk mengisi celah penelitian sebelumnya.

Inkonsistensi pada penelitian sebelumnya menjadikan celah penelitian ini dalam mengisi gap penelitian. Penelitian ini bertujuan untuk mengetahui bagaimana implementasi metode Naive Bayes dalam klasifikasi sampah.

Metode

Naive Bayes adalah algoritma klasifikasi yang berdasarkan pada Teorema Bayes dengan asumsi kuat bahwa setiap fitur bersifat independen satu sama lain [16],[17]. Metode pengklasifikasian dengan menggunakan metode probabilitas dan statistik yaitu memprediksi peluang di masa depan berdasarkan pengalaman di masa sebelumnya sehingga dikenal sebagai Teorema Bayes [18]. Formula dasar dari Teorema Bayes ditunjukkan pada (1).

$$P(C | X) = \frac{P(X | C) \cdot P(C)}{P(X)} \quad (1)$$

Di mana $P(C | X)$ merupakan probabilitas suatu data X termasuk dalam kelas C (disebut *posterior probability*). Nilai ini dihitung berdasarkan $P(C | X)$, yaitu probabilitas data X muncul jika diketahui kelasnya C (*likelihood*), dikalikan dengan $P(C)$, yaitu probabilitas awal terjadinya kelas C tanpa mempertimbangkan data (*prior*). Kemudian dibagi dengan $P(X)$, yaitu probabilitas keseluruhan dari data X (*evidence*). Rumus ini menjadi dasar dalam proses klasifikasi menggunakan pendekatan probabilistik.


Salah satu varian dari algoritma Naive Bayes adalah Gaussian Naive Bayes, yang digunakan ketika fitur bersifat kontinu. Dalam pendekatan ini, diasumsikan bahwa setiap fitur yang terdapat dalam data mengikuti distribusi normal (Gaussian) pada setiap kelas [19], [20]. Oleh karena itu, probabilitas kemunculan suatu nilai fitur x_i terhadap kelas C_k dihitung menggunakan persamaan (2).

$$P(x_i | C_k) = \frac{1}{\sqrt{2\pi\sigma_k^2}} \exp\left(-\frac{(x_i - \mu_k)^2}{2\sigma_k^2}\right) \quad (2)$$

Di mana μ_k adalah rata-rata dan σ_k^2 adalah varians dari fitur x_i pada kelas C_k . Persamaan ini memungkinkan model untuk menghitung kemungkinan suatu nilai fitur diberikan kelas tertentu, sehingga bisa digunakan dalam perhitungan probabilitas posterior seperti pada rumus dasar Naive Bayes. Gaussian Naive Bayes sangat cocok digunakan pada dataset dengan fitur numerik yang tersebar secara normal.

Perancangan

Pada Gambar 1 menunjukkan alur penelitian. Dimulai dari pembagian dataset 80 untuk pelatihan dan 20 untuk pengujian kemudian dilakukan resize pada gambar dengan ukuran 64 x 64 pixel dan di lakukan normalisasi, selanjutnya di klasifikasikan menggunakan model Naive Bayes dan di ukur menggunakan metrik evaluasi seperti akurasi, presisi, recall dan f1- score .



Gambar 1. Alur Penelitian

A. Dataset

Pada Penelitian ini menggunakan dataset publik dari website Kaggle yang terdiri dari 997 gambar dimana dibagi menjadi 2 kelas yaitu kelas kertas yang terdiri dari 594 gambar kertas dan 403 gambar karton. Data tersebut kemudian dibagi menjadi data pelatihan 80% dan pengujian 20%.

B. Preprocessing

1. Resize

Resize 64×64 adalah proses mengubah ukuran citra menjadi resolusi tetap dengan lebar 64 piksel dan tinggi 64 piksel [21]. Tahap ini dilakukan untuk menyeragamkan ukuran citra pada dataset

sehingga dapat diproses secara konsisten oleh model, sekaligus mengurangi kompleksitas komputasi karena resolusi yang lebih kecil membuat proses pelatihan lebih cepat dan efisien. Selain itu, penggunaan ukuran 64×64 sering dipilih karena sesuai dengan kebutuhan input pada beberapa arsitektur model deep learning. Meskipun demikian, konsekuensi dari resize ini adalah hilangnya sebagian detail citra akibat berkurangnya resolusi, namun ukuran tersebut umumnya masih mampu merepresentasikan pola atau ciri utama dari objek yang diteliti.

2. Normalisasi

Normalisasi adalah proses transformasi data ke dalam skala tertentu agar lebih seragam dan mudah diproses oleh algoritma. Pada citra digital, normalisasi umumnya dilakukan dengan mengubah nilai piksel yang semula berada pada rentang 0–255 menjadi skala baru, misalnya 0–1 atau –1 sampai 1 [22]. Tujuan utama dari normalisasi adalah meningkatkan stabilitas perhitungan, mempercepat proses pelatihan model, serta membantu algoritma pembelajaran mesin atau deep learning dalam mengenali pola secara lebih efektif. Dengan data yang telah dinormalisasi, perbedaan skala antar fitur dapat diminimalisasi sehingga model tidak bias terhadap nilai dengan rentang lebih besar, serta kinerja prediksi dapat menjadi lebih optimal.

C. Klasifikasi

Naïve Bayes adalah salah satu algoritma klasifikasi yang didasarkan pada Teorema Bayes dengan asumsi bahwa setiap fitur bersifat independen satu sama lain. Algoritma ini menghitung probabilitas suatu data termasuk ke dalam kelas tertentu berdasarkan distribusi peluang dari fitur-fiturnya, kemudian memilih kelas dengan probabilitas tertinggi sebagai hasil prediksi. Meskipun asumsi independensi antar fitur sering kali tidak sepenuhnya terpenuhi dalam data nyata, Naïve Bayes tetap efektif digunakan karena sederhana, cepat dalam proses pelatihan, serta mampu memberikan hasil yang cukup baik pada berbagai permasalahan klasifikasi, termasuk pengolahan teks, analisis sentimen, maupun pengenalan pola dalam citra.

D. Evaluasi

Evaluasi kinerja model klasifikasi dapat dilakukan dengan menggunakan beberapa metrik, yaitu Accuracy, Precision, Recall, dan F1-Score. *Accuracy* mengukur proporsi prediksi yang benar dibandingkan dengan seluruh data, sehingga menunjukkan seberapa tepat model dalam melakukan klasifikasi secara keseluruhan. *Precision* menilai ketepatan prediksi positif, yaitu seberapa banyak data yang diprediksi positif benar-benar termasuk dalam kelas positif, sehingga penting untuk mengurangi kesalahan positif palsu (false positive). *Recall* mengukur kemampuan model dalam menemukan seluruh data positif, yaitu seberapa banyak data positif yang berhasil dideteksi dibandingkan dengan total data positif yang ada, sehingga berhubungan dengan kesalahan negatif palsu (false negative). Sementara itu, *F1-Score* merupakan rata-rata harmonis antara Precision dan Recall yang memberikan keseimbangan ketika kedua metrik tersebut memiliki nilai yang tidak seimbang. Keempat metrik ini saling melengkapi dan sering digunakan untuk memberikan gambaran yang lebih komprehensif terhadap performa suatu model klasifikasi.

Untuk memberikan gambaran yang lebih jelas mengenai perhitungan metrik dalam evaluasi model, persamaan (3) - (6) digunakan sebagai rumus untuk menghitung F1-score, recall, akurasi, dan presisi.

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

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

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

$$F1\text{-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (6)$$

True Positive (TP) adalah jumlah prediksi positif yang benar, sedangkan True Negative (TN) adalah jumlah prediksi negatif yang benar. False Positive (FP) mengacu pada jumlah prediksi positif yang salah, dan False Negative (FN) adalah jumlah prediksi negatif yang salah.

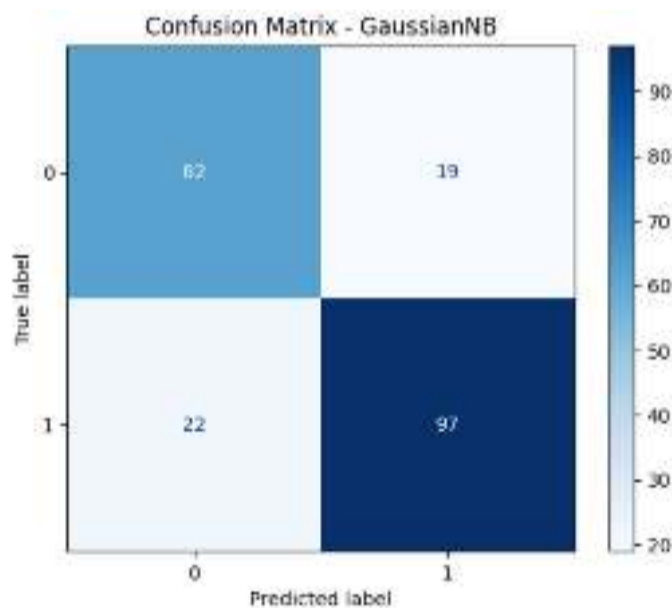
Pemodelan

Pada penelitian ini, model Naïve Bayes dievaluasi menggunakan dua jenis pendekatan, yaitu Gaussian Naïve Bayes dan Multinomial Naïve Bayes. Evaluasi dilakukan berdasarkan accuracy, precision, recall, dan F1-score untuk menilai performa dari masing-masing metode. Hasil evaluasi ditampilkan dalam Tabel 1, yang menunjukkan bahwa penggunaan Gaussian Naïve Bayes menghasilkan kinerja terbaik dengan nilai accuracy sebesar 79.50%, sedangkan Multinomial Naïve Bayes hanya mencapai 59.50%. Selain itu, metrik precision, recall, dan F1-score juga menunjukkan tren yang serupa, di mana Gaussian Naïve Bayes tetap unggul dibandingkan dengan Multinomial Naïve Bayes. Hal ini menunjukkan bahwa pemilihan varian algoritma Naïve Bayes memiliki pengaruh signifikan terhadap performa model klasifikasi.

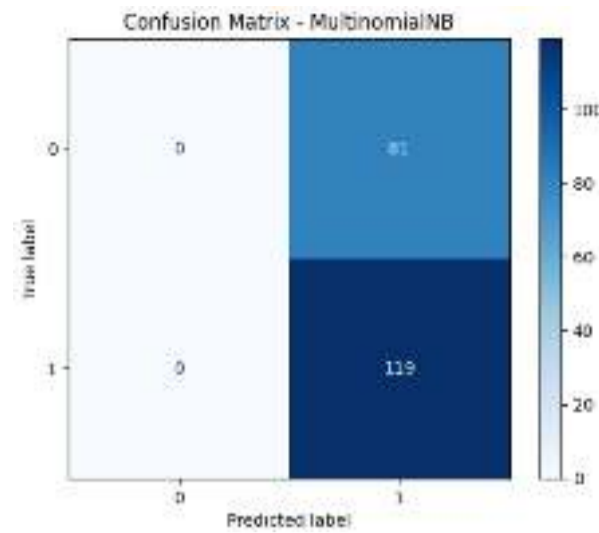
Tabel 1. Hasil dari Model Algoritma KNN

Kernel	Accuracy	Precision	Recall	F1 - Score
GaussianNB	79.50 %	80 %	80 %	80 %
MultinomialNB	59.50 %	35 %	59 %	44 %

Berdasarkan Tabel 1, dapat dilihat bahwa Gaussian Naïve Bayes (GaussianNB) memiliki performa yang lebih baik dibandingkan dengan Multinomial Naïve Bayes (MultinomialNB). GaussianNB memperoleh nilai *accuracy* sebesar 79.50%, dengan *precision*, *recall*, dan *F1-score* masing-masing sebesar 80%, menunjukkan bahwa model ini mampu memberikan prediksi yang seimbang antara ketepatan dan kemampuan mendeteksi kelas positif. Sementara itu, MultinomialNB hanya mencapai *accuracy* sebesar 59.50%, dengan nilai *precision* sebesar 35%, *recall* sebesar 59%, dan *F1-score* sebesar 44%. Nilai *precision* yang rendah pada MultinomialNB mengindikasikan bahwa model ini sering menghasilkan prediksi positif yang keliru, meskipun nilai *recall*-nya menunjukkan kemampuan moderat dalam mendeteksi data positif. Secara keseluruhan, hasil ini memperlihatkan bahwa GaussianNB lebih sesuai untuk dataset yang digunakan dalam penelitian ini dibandingkan MultinomialNB, karena mampu memberikan kinerja yang lebih stabil dan akurat pada semua metrik evaluasi. Gambar 2 Menunjukkan Confusion Matrix dari kernel GaussianNB dan Gambar 3 Menunjukkan Confusion Matrix dari kernel MultinomialNB.

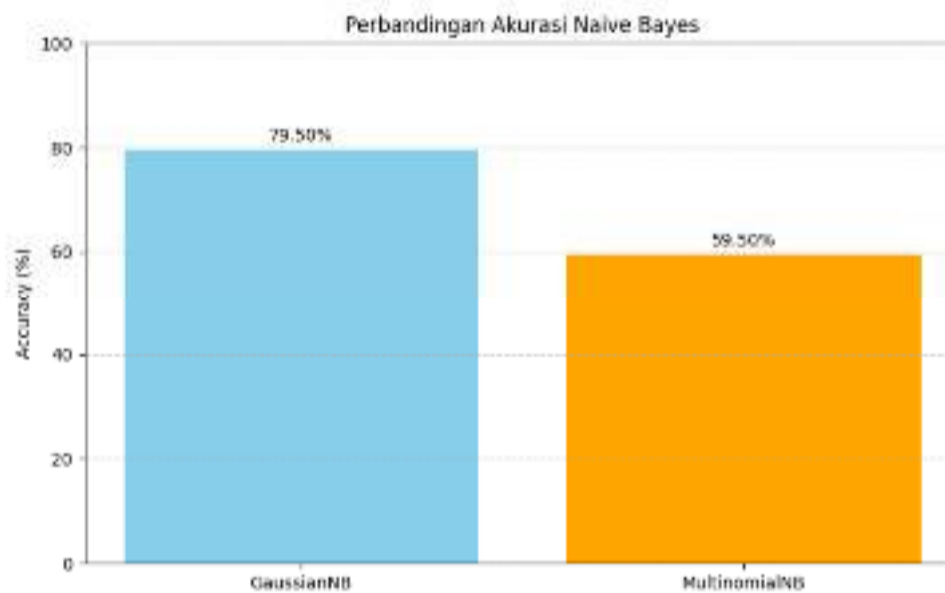


Gambar 2. Confusion Matrix dari Model Naïve Bayes dengan Kernel GaussianNB



Gambar 3. *Confusion Matrix* dari Model Naive Bayes dengan Kernel MultinomialNB

Gambar 4 menunjukkan bandingan akurasi antara Gaussian Naïve Bayes (GaussianNB) dan Multinomial Naïve Bayes (MultinomialNB). Dari grafik terlihat jelas bahwa GaussianNB memperoleh akurasi lebih tinggi, yaitu sebesar 79.50%, sedangkan MultinomialNB hanya mencapai 59.50%. Perbedaan ini menunjukkan bahwa GaussianNB lebih sesuai digunakan pada dataset penelitian ini, kemungkinan karena distribusi fitur yang mendekati distribusi normal sehingga lebih sesuai dengan asumsi dasar GaussianNB. Sebaliknya, MultinomialNB yang umumnya lebih optimal untuk data berbasis frekuensi (seperti teks atau data diskrit) kurang mampu menangkap pola pada dataset ini, sehingga menghasilkan akurasi yang lebih rendah. Dengan demikian, dapat disimpulkan bahwa GaussianNB memberikan kinerja yang lebih baik dibandingkan MultinomialNB dalam tugas klasifikasi pada penelitian ini.



Gambar 4. Bart Chart Perbandingan Akurasi GaussianNB dan MultinomialNB

Kesimpulan

Berdasarkan hasil penelitian, metode Naïve Bayes mampu digunakan dalam klasifikasi citra sampah dengan cukup baik. Dari dua pendekatan yang digunakan, yaitu Gaussian Naïve Bayes dan Multinomial Naïve Bayes, diperoleh bahwa Gaussian Naïve Bayes memberikan performa yang lebih unggul dengan nilai *accuracy* sebesar 79.50%, serta *precision*, *recall*, dan *F1-score* masing-masing sebesar 80%. Sementara itu, Multinomial Naïve Bayes hanya mencapai *accuracy* sebesar 59.50%, dengan nilai *precision* sebesar 35%, *recall* sebesar 59%, dan *F1-score* sebesar 44%. Hasil ini menunjukkan bahwa Gaussian Naïve Bayes lebih sesuai untuk

digunakan dalam penelitian ini, kemungkinan karena karakteristik data yang lebih mendekati distribusi normal, sehingga model dapat mengklasifikasikan sampah dengan lebih akurat dan seimbang. Dengan demikian, pemilihan varian algoritma Naïve Bayes berperan penting dalam menentukan kinerja klasifikasi, dan Gaussian Naïve Bayes dapat dijadikan alternatif yang efektif dalam mendukung sistem pengelolaan sampah berbasis teknologi.

Daftar Pustaka

- [1] R. Kurniawan, P. Wintoro, Y. Mulyani, and M. Komarudin, "Implementasi Arsitektur Xception pada Model Machine Learning Klasifikasi Sampah Anorganik," *J. Inform. dan Tek. Elektro Terap.*, vol. 11, Apr. 2023, doi: 10.23960/jitet.v11i2.3034.
- [2] Nurikah, E. R. Jajuli, H, and E. Furqon, "Waste Management Governance Based On Law Number 18 Of 2008 Of Waste Management Of Waste Based Citizen Participation In The Serang City," *Gorontalo Law Rev.*, vol. 5, no. 2, pp. 434–442, 2022.
- [3] G. Nugroho, M. Muslikh, A. Hidayah, U. D. Indrayani, and A. M. Marzuqi, "Sosialisasi Penanganan Sampah di Dukuh Sawahan, Pendowoharjo, Sewon Bantul, Daerah Istimewa Yogyakarta," *J. Pengabd. Masy. Sains dan Teknol.*, vol. 3, no. 3, pp. 75–81, 2024.
- [4] H. Darwis, R. Puspitasari, Purnawansyah, W. Astuti, D. Atmajaya, and M. Hasnawi, "A Deep Learning Approach for Improving Waste Classification Accuracy with ResNet50 Feature Extraction," in *2025 19th International Conference on Ubiquitous Information Management and Communication (IMCOM)*, 2025, pp. 1–8. doi: 10.1109/IMCOM64595.2025.10857536.
- [5] M. Lanotte and L. Desidery, "6 - Rutting of waste plastic-modified bitumen," in *Woodhead Publishing Series in Civil and Structural Engineering*, F. Giustozzi and S. B. T.-P. W. for S. A. R. Nizamuddin, Eds., Woodhead Publishing, 2022, pp. 97–114. doi: <https://doi.org/10.1016/B978-0-323-85789-5.00006-X>.
- [6] M. Hassaballah, Y. M. Wazery, I. E. Ibrahim, and A. Farag, "ECG Heartbeat Classification Using Machine Learning and Metaheuristic Optimization for Smart Healthcare Systems," *Bioengineering*, vol. 10, no. 4, pp. 1–16, 2023, doi: 10.3390/bioengineering10040429.
- [7] S. Khodijah and J. M. L. Tobing, "Tinjauan Plastik Biodegradable dari Limbah Tanaman Pangan sebagai Kantong Plastik Mudah Terurai," *Teknotan*, vol. 17, no. 1, p. 21, 2023, doi: 10.24198/jt.vol17n1.3.
- [8] V. Situmeang, R. S. Santoso, and H. Warsono, "No Title," *J. Public Policy Manag. Rev. Vol 12, No 4 Oktober 2023DO* - 10.14710/jppmr.v12i4.41393 , Oct. 2023, [Online]. Available: <https://ejournal3.undip.ac.id/index.php/jppmr/article/view/41393>

- [9] D. A. S. Ermal *et al.*, “Penyuluhan Pemanfaatan Limbah Organik Sisa Dapur menjadi Eco Enzyme dengan Teknik Persuasif kepada Masyarakat di Perumahan Griya Rumaisha Tenayan Raya,” *J. Pengabd. UntukMu NegeRI*, vol. 7, no. 1, 2023, doi: 10.37859/jpumri.v7i1.4639.
- [10] U. M. Khoir *et al.*, “Pengelolaan Sampah Anorganik Melalui Alat Pembakar Sampah Alternatif untuk Mewujudkan Lingkungan Sehat,” *Pros. Semin. Nas. Progr. Pengabd. Masy. Univ. Muhammadiyah Yogyakarta*, vol. 8, no. 1, pp. 307–317, 2025, [Online]. Available: <https://prosiding.umy.ac.id/semnasppm/index.php/psppm/article/view/1297/1259>
- [11] A. E. Minarno, I. Soesanti, and H. A. Nugroho, “Batik Classification using Microstructure Co-occurrence Histogram,” *Int. J. Informatics Vis.*, vol. 8, no. 1, pp. 134–140, 2024, doi: 10.62527/joiv.8.1.2152.
- [12] S. Sharma and K. Guleria, “A Deep Learning based model for the Detection of Pneumonia from Chest X-Ray Images using VGG-16 and Neural Networks,” *Procedia Comput. Sci.*, vol. 218, pp. 357–366, 2023, doi: <https://doi.org/10.1016/j.procs.2023.01.018>.
- [13] Marthin Luter Laia and Yudi Setyawan, “Perbandingan Hasil Klasifikasi Curah Hujan Menggunakan Metode SVM dan NBC,” *J. Stat. Ind. dan Komputasi*, vol. 5, no. 2, pp. 51–61, 2020.
- [14] A. M. Jon, “Analisis Sentimen Pada Media Sosial Instagram Klub Persija Jakarta Menggunakan Metode Naive Bayes,” *Automata*, vol. 958, pp. 1–8, 2022.
- [15] M. Y. Prabudifa, O. S. Mayangsari, A. Desiani, D. A. Zayanti, R. Primartha, and D. Novita, “Ensemble Classifier dengan Teknik Weighted Voting untuk Klasifikasi Jamur Beracun,” *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 12, no. 2, pp. 39–50, 2025, doi: 10.35957/jatisi.v12i2.10168.
- [16] R. Hayami, Soni, and I. Gunawan, “Klasifikasi Jamur Menggunakan Algoritma Naïve Bayes,” *J. CoSciTech (Computer Sci. Inf. Technol.)*, vol. 3, no. 1, pp. 28–33, 2022, doi: 10.37859/coscitech.v3i1.3685.
- [17] M. Edalati, A. S. Imran, Z. Kastrati, and ..., “The potential of machine learning algorithms for sentiment classification of students’ feedback on MOOC,” *Intell. Syst. ...*, 2022, doi: 10.1007/978-3-030-82199-9_2.
- [18] O. Yaman and K. Demir, “A HOG Feature Extractor and KNN-Based Method for Underwater Image Classification TT - Su Altı Görüntü Sınıflandırma için HOG Özellik Çıkarıcı ve KNN Tabanlı Bir Yöntem,” *Firat Univ. J. Exp. Comput. Eng.*, vol. 3, no. 1, pp. 1–10, 2024, doi: 10.62520/fujece.1443818.

- [19] S. Naiem, A. E. Khedr, A. M. Idrees, and M. I. Marie, "Enhancing the Efficiency of Gaussian Naïve Bayes Machine Learning Classifier in the Detection of DDOS in Cloud Computing," *IEEE Access*, vol. 11, pp. 124597–124608, 2023, doi: 10.1109/ACCESS.2023.3328951.
- [20] R. Islam, M. K. Devnath, M. D. Samad, and S. M. Jaffrey Al Kadry, "GGNB: Graph-based Gaussian naive Bayes intrusion detection system for CAN bus," *Veh. Commun.*, vol. 33, p. 100442, 2022, doi: <https://doi.org/10.1016/j.vehcom.2021.100442>.
- [21] M. Samir, Purnawansyah, H. Darwis, and F. Umar, "Fourier Descriptor Pada Klasifikasi Daun Herbal Menggunakan Support Vector Machine Dan Naive Bayes," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, pp. 1205–1212, Dec. 2023, doi: 10.25126/jtiik.1067309.
- [22] H. Darwis, Z. Ali, Y. Salim, and P. L. L. Belluano, "Max Feature Map CNN with Support Vector Guided SoftMax for Face Recognition," *Int. J. Informatics Vis.*, vol. 7, no. 3, pp. 959–966, 2023, doi: 10.30630/joiv.7.3.1751.