



Klasifikasi Preferensi Destinasi Wisata Gunung dan Pantai Menggunakan Metode *Deep Learning*

Andin Ayu Oksilia Ramadhani¹, Bambang Irawan²

^{1,2}Program Studi Teknik Informatika, Universitas Muhadi Setiabudi, Indonesia

Email author: oksiliaandin279@gmail.com¹, bambangumus@gmail.com²

Article Info

Article history:

Received September 3, 2025

Revised Desember 3, 2025

Accepted Desember 14, 2025

Keywords:

Beaches

Deep Learning

Multilayer Perceptron

Mountains

Tourism Preference

Classification

ABSTRACT

Tourism is one of the sectors that plays an important role in boosting economic growth through travel activities and destination exploration. Tourists' preferences for nature-based tourism options, such as mountain hiking or beach tourism, are influenced by various factors, ranging from personal experiences and recreational interests to social characteristics. Therefore, a technology-based approach is needed to predict destination choice tendencies more accurately.

As artificial intelligence technology develops, deep learning methods have been widely used in classification processes due to their ability to process large amounts of data and recognize complex patterns. In this study, a Multilayer Perceptron (MLP) model is used to classify tourists' preferences between mountain or beach destinations based on a survey dataset. The research stages include data processing, data splitting using a train-test split, model training, and performance evaluation using accuracy, precision, recall, and F1-score.

The test results show that the MLP model is capable of achieving an accuracy rate of 99%, confirming that deep learning methods are effective in automatically mapping tourism preference trends. This research is expected to serve as a basis for the development of more personalized travel destination recommendation systems, as well as to support tourism management in formulating targeted promotional strategies.

Corresponding Author:

Andin Ayu Oksilia Ramadhani,

Universitas Muhadi Setiabudi

Jl. Pangeran Diponegoro No,KM2. Rw.11,Pesantunan, Kec.Wanasari, Kabupaten Brebes, Jawa Tengah

Email: oksiliaandin279@gmail.com



1. PENDAHULUAN

Pariwisata merupakan sektor penting yang berkontribusi signifikan terhadap pertumbuhan ekonomi nasional melalui peningkatan aktivitas perjalanan, eksplorasi destinasi wisata dan penguatan nilai sosial budaya. Aktivitas wisata alam seperti pendakian gunung dan wisata pantai menjadi pilihan populer bagi wisatawan karena menawarkan pengalaman rekreasi dan petualangan. Preferensi individu terhadap pilihan destinasi wisata dipengaruhi berbagai faktor seperti pengalaman berwisata, motivasi, kebutuhan rekreasi dan karakteristik sosial. Analisis perilaku wisatawan berbasis data digital juga menunjukkan bahwa pola minat

wisatawan berbasis data digital juga menunjukkan bahwa pola minat wisatawan dapat dipetakan secara sistematis menggunakan pendekatan berbasis data [1].

Dalam konteks pengelolaan pariwisata, pemanfaatan teknologi kecerdasan buatan menjadi solusi penting untuk menghasilkan analisis yang lebih akurat dan objektif. Perkembangan *machine learning* dan *deep learning* memungkinkan proses klasifikasi yang lebih baik pada dataset kompleks serta mendukung keputusan berbasis data. Berbagai penelitian menunjukkan bahwa model *deep learning* memiliki performa tinggi dalam menyelesaikan masalah klasifikasi pada domain kesehatan, citra dan objek fisik, serta mampu menangani variasi data kompleks secara efektif [2], [3].

Salah satu metode *deep learning* yang paling banyak digunakan adalah *Multilayer Perceptron* (MLP), karena memiliki kemampuan mempelajari hubungan non-linear melalui lapisan tersembunyi. Penelitian sebelumnya membuktikan bahwa MLP mampu menghasilkan akurasi tinggi pada klasifikasi medis objek realistis seperti identifikasi penyakit Dengue dan Tifus dengan akurasi mencapai 98,68% [3] serta klasifikasi objek bawah laut dengan akurasi maksimum 96,15% [2]. Selain itu, implementasi *deep learning* menunjukkan efektivitas signifikan pada klasifikasi objek visual kompleks serta pembelajaran pola fitur multidimensional [4]. Model MLP juga terbukti mampu menangani ketidakseimbangan data dan meningkatkan akurasi prediksi pada kasus kesehatan kritis [5].

Namun, penelitian terkait penerapan model *deep learning* untuk klasifikasi preferensi destinasi wisata berbasis profil wisatawan pribadi masih sangat terbatas. Studi sebelumnya lebih berfokus pada analisis perilaku wisatawan berdasarkan ulasan daring dan persepsi terhadap kualitas layanan destinasi wisata [1]. Hal ini menunjukkan masih terdapat ruang penelitian untuk mengembangkan sistem berbasis data yang dapat memetakan kecenderungan preferensi wisata secara personal, terutama pada perbandingan pilihan wisata gunung dan pantai.

Berdasarkan gap penelitian tersebut, penelitian ini mengusulkan penerapan metode *deep learning* berbasis MLP untuk mengklasifikasikan preferensi destinasi wisata antara gunung dan pantai berdasarkan dataset dari platform Kaggle. Sistem ini diharapkan dapat menjadi alat pendukung pengambilan keputusan dalam pengelolaan pariwisata serta mendukung perancangan strategi promosi berbasis data yang lebih tepat sasaran. Inovasi penelitian ini terletak pada penerapan model *deep learning* untuk memprediksi preferensi destinasi wisata, yang belum banyak dilakukan pada penelitian sebelumnya, terutama pada domain pariwisata berbasis data kuantitatif.

2. METODE

Penelitian ini menggunakan metode kuantitatif dengan pendekatan klasifikasi berbasis *deep learning*, khususnya algoritma *Multilayer Perceptron* (MLP). Tujuan utama penelitian ini adalah membangun model yang mampu memprediksi preferensi wisatawan terhadap destinasi gunung atau pantai menggunakan data perilaku dan karakteristik. Proses penelitian meliputi pengumpulan data, *preprocessing*, pelatihan model, serta evaluasi performa menggunakan metrik akurasi, *precision*, *recall* dan *F1-score*. Penggunaan MLP banyak diterapkan pada tugas klasifikasi karena kemampuannya mengolah pola non-linear dalam data. Metode yang digunakan adalah algoritma *Multilayer Perceptron* (MLP), yang dikenal efektif dalam menangani permasalahan klasifikasi non-linear dengan performa tinggi pada berbagai domain, seperti pengklasifikasian objek bawah laut [2], identifikasi penyakit [3], dan prediksi kesehatan menggunakan teknik balancing data [5].

2.1. Sumber Data

Dataset diperoleh dari platform Kaggle berjudul “*Mountain vs Beaches Preferences Dataset*” yang disusun oleh Paliwal (2023) [6]. Dataset ini berisi 10.489 entri pengguna, mencakup informasi demografis, pengalaman perjalanan, serta aktivitas wisata yang diminati. Struktur data yang kaya membuat dataset ini sesuai untuk pemodelan klasifikasi berbasis *deep learning* sebagaimana diterapkan pula dalam penelitian pariwisata berbasis data [1] dan *framework* analitik *big data*.

2.2. Tahapan *Preprocessing Data*

Sebelum melakukan pelatihan model, dataset melalui beberapa tahap *processing* untuk menjamin kualitas dan konsistensi data. Tahapan tersebut meliputi:

1. Pembersihan Data (*Cleaning*)

Nilai kosong dan duplikasi dihapus agar dataset berada dalam kondisi stabil. Pendekatan pembersihan data seperti ini umum dilakukan pada penelitian *deep learning* di bidang kesehatan dan pendidikan untuk meningkatkan konsistensi *input* model [3], [7].

2. Encoding Variabel Kategorikal

Variabel non-numerik dikonversi menggunakan teknik label *encoding* agar dapat diproses oleh jaringan saraf. Metode serupa digunakan dalam penelitian penyakit jantung berbasis MLP [5].

3. Normalisasi Data

Fitur numerik dinormalisasi untuk menyeragamkan rentang nilai. Normalisasi terbukti membantu stabilitas pembelajaran jaringan syaraf sebagaimana ditunjukkan dalam penelitian citra objek [2] dan klasifikasi makrofungi berbasis *deep learning* [4].

4. Pembagian Data

Dataset dibagi menjadi 80% data latih dan 20% data uji menggunakan skema *train-test split* yang umum digunakan pada penelitian klasifikasi modern untuk menilai generalisasi model [4], [7].

2.3. Perancangan Model *Multilayer Perceptron* (MLP)


Model MLP yang digunakan terdiri dari:

1. *Input layer* sesuai jumlah fitur.
2. Beberapa *hidden layer* dengan aktivitas ReLU untuk menangkap relasi non-linear.
3. *Output layer* dengan aktivasi sigmoid untuk klasifikasi biner (Gunung/Pantai).

Pemilihan arsitektur ini didukung oleh penelitian sebelumnya yang menunjukkan bahwa MLP memiliki performa tinggi pada klasifikasi objek bawah laut (akurasi 96.15%) [2], dan prediksi kesehatan berbasis *balancing technique* (SMOTE-ENN) [5]. Optimasi model dilakukan menggunakan algoritma Adam, dengan *binary cross-entropy* sebagai fungsi *loss*.

2.4. Alur Penelitian

Tahapan penelitian digambarkan pada Gambar 1. Diagram ini mencerminkan seluruh proses mulai dari akuisisi data, *preprocessing*, desain model, pelatihan, evaluasi hingga analisis hasil mengikuti struktur penelitian MLP pada berbagai domain [2]–[4].



Gambar 1. *Research workflow of the MLP-based tourism preference classification model.*

2.5. Evaluasi Model

Evaluasi dilakukan menggunakan empat metrik utama:

1. *Accuracy*
2. *Precision*
3. *Recall*
4. *F1-score*

Penggunaan metrik ini mengikuti standar penelitian klasifikasi berbasis deep learning pada bidang medis [3], objek underwater [2], maupun makrofungi [4].

Hasil evaluasi model (Tabel 1) menunjukkan:

Tabel 1. Hasil Evaluasi Model MLP

Metrik	Nilai
<i>Accuracy</i>	99%
<i>Precision</i>	0.98
<i>Recall</i>	0.99
<i>F1-Score</i>	0.98

Akurasi tinggi ini menunjukkan performa model yang stabil tanpa indikasi *overfitting*, sebagaimana dicatat pula dalam penelitian klasifikasi kesehatan dan geospasial menggunakan arsitektur MLP [3], [7].

3. HASIL DAN PEMBAHASAN

3.1. Analisis Dataset dan Tahapan *Preprocessing*

Dataset yang digunakan dalam penelitian ini berasal dari platform Kaggle dengan judul “*Mountains vs Beaches Preferences Dataset*”, yang berisi 10.489 data responden terkait preferensi destinasi wisata antara gunung dan pantai [6]. Dataset ini memuat informasi mengenai demografi, pengalaman perjalanan, aktivitas yang diminati, serta kecenderungan wisata responden, sehingga memberikan variasi fitur yang cukup untuk pemodelan berbasis *deep learning*.

Tahapan *preprocessing* dilakukan untuk memastikan setiap fitur berada pada format dan skala yang sesuai sebelum digunakan untuk pelatihan model. Proses ini mencakup pembersihan data dari nilai hilang, normalisasi fitur numerik, serta *encoding* variabel kategorikal. Pendekatan *preprocessing* seperti ini juga diterapkan dalam penelitian sebelumnya yang menggunakan MLP untuk klasifikasi kesehatan dan pendidikan, dimana *processing* terbukti mampu meningkatkan stabilitas model [3], [5], [7]. Normalisasi membantu menyelaraskan rentang nilai fitur, sedangkan *encoding* memungkinkan fitur kategorikal diubah menjadi representasi numerik yang dapat dipahami jaringan saraf.

Selain itu, proses *preprocessing* pada penelitian ini juga mengikuti kaidah umum pengolahan data tabular yang digunakan dalam studi terkait klasifikasi *multilayer perceptron* [8], [9], [10]. Setelah *preprocessing*, dataset dibagi menggunakan *train-test split* dengan rasio 80:20, yang merupakan pendekatan umum untuk menilai kemampuan generalisasi model dalam penelitian klasifikasi modern [7], [11]. Pembagian ini memastikan bahwa model memiliki data latihan yang cukup luar, sekaligus menyediakan data uji yang representatif.

3.2. Hasil Pelatihan dan Evaluasi Model

Model *Multilayer Perceptron* (MLP) digunakan sebagai algoritma utama dalam penelitian ini. Arsitektur model terdiri dari beberapa *hidden layer* berfungsi aktivasi ReLU untuk menangkap relasi non-linear antar fitur, serta *output layer* dengan fungsi aktivasi sigmoid untuk menghasilkan prediksi biner. Pendekatan

ini digunakan secara luas pada studi kasus berbasis *deep learning* karena kemampuannya dalam menangani data kompleks dan berdimensi tinggi [2], [4], [12].

Model dilatih menggunakan data latih yang telah diproses dan dievaluasi pada data uji dengan menggunakan empat metrik umum, yaitu *accuracy*, *precision*, *recall* dan *F1-score* [7], [13]. Hasil evaluasi ditampilkan pada Tabel 1.

Akurasi 99% menunjukkan bahwa model mampu melakukan prediksi dengan tingkat kesalahan yang sangat kecil. *Precision* yang mendekati sempurna menunjukkan rendahnya kesalahan pada prediksi positif, sedangkan *recall* yang tinggi mengindikasikan kemampuan model dalam menangkap sampel pada kedua kelas secara konsisten. Nilai *F1-score* yang stabil memperlihatkan bahwa model bekerja secara seimbang baik dalam menghindari kesalahan prediksi maupun menangkap pola yang relevan. Performansi ini sejalan dengan beberapa penelitian sebelumnya yang melaporkan bahwa MLP efektif untuk data tabular dengan karakteristik non linear [2], [4], [14].

Selain itu, evaluasi ini menunjukkan bahwa model tidak mengalami indikasi *overfitting*, ditandai dengan kesesuaian antara performa data latih dan uji. Stabilitas model juga sejalan dengan temuan penelitian pada domain non-pariwisata seperti klasifikasi tanah, monitoring sensor dan prediksi kesehatan yang menekankan pentingnya pemilihan arsitektur MLP yang tepat [4], [14], [10].

3.2.1. Analisis Kesalahan Klasifikasi

Walaupun performa model sangat tinggi, beberapa kesalahan klasifikasi tetap ditemukan pada data uji. Berdasarkan inspeksi manual, sebagian besar kesalahan terjadi pada sampel dengan karakteristik preferensi yang tidak konsisten atau ambigu. Misalnya, pengguna yang menyukai aktivitas alam namun juga memiliki preferensi tinggi terhadap aktivitas rekreasi pantai, sehingga pola perilakunya tidak cukup jelas untuk dipetakan secara tegas oleh model.

Fenomena seperti ini juga ditemukan dalam penelitian perilaku wisatawan berbasis ulasan online, di mana faktor subjektivitas menyebabkan pola preferensi menjadi tidak stabil dan meningkatkan risiko kesalahan klasifikasi [1], [15]. Selain itu, noise kecil pada fitur tertentu berpotensi memengaruhi pembentukan batas keputusan model, terutama pada data yang memiliki kecenderungan ganda.

Meski demikian, jumlah kesalahan tersebut sangat kecil dan tidak berdampak signifikan terhadap performa keseluruhan, sebagaimana ditunjukkan oleh nilai *F1-score* yang tetap tinggi. Kondisi ini menunjukkan bahwa model memiliki ketahanan yang baik meskipun berhadapan dengan data yang tidak sepenuhnya jelas pola preferensinya [4], [9].

3.2.2. Analisis Performa Model MLP

Kinerja model yang sangat tinggi didukung oleh beberapa faktor penting. Pertama, ukuran dataset yang besar memungkinkan model untuk mempelajari pola preferensi yang beragam dan kompleks. Hal ini berkontribusi pada kemampuan generalisasi yang kuat, sebagaimana juga diobservasi pada penelitian *deep learning* dengan dataset besar [11].

Kedua, pemilihan arsitektur MLP tepat untuk menangani karakteristik data tabular yang umum ditemukan pada penelitian pariwisata, kesehatan, dan lingkungan [2], [14], [16]. Struktur jaringan yang terdiri dari beberapa lapisan tersembunyi mampu membangun representasi fitur yang lebih mendalam sehingga model dapat mengidentifikasi hubungan kompleks yang tidak dapat ditangkap oleh metode klasik.

Ketiga, *preprocessing* yang dilakukan seperti normalisasi dan *encoding* membantu menyelaraskan data dan mengurangi potensi gangguan akibat perbedaan skala antar fitur. Berbagai studi membuktikan bahwa *preprocessing* yang tepat dapat meningkatkan stabilitas pembelajaran pada model MLP dan mencegah bias pada proses klasifikasi [3], [7], [8].

Secara keseluruhan, hasil penelitian ini memperkuat temuan bahwa MLP merupakan salah satu pendekatan *deep learning* yang paling efektif untuk memodelkan data preferensi wisata dan data tabular secara umum. Dengan performa yang sangat tinggi, pendekatan ini berpotensi diterapkan dalam sistem rekomendasi destinasi wisata berbasis kecerdasan buatan untuk menyajikan rekomendasi yang lebih personal dan relevan bagi pengguna.

4. KESIMPULAN

Hasil penelitian menunjukkan bahwa algoritma *Multilayer Perceptron* (MLP) mampu memetakan preferensi wisata pengguna dengan tingkat akurasi yang sangat tinggi. Kinerja ini menunjukkan bahwa struktur jaringan berlapis dapat menangkap relasi non-linear yang muncul pada data tabular seperti demografi, preferensi aktivitas, dan perilaku perjalanan. Temuan ini selaras dengan berbagai studi yang menyatakan bahwa

MLP cocok digunakan pada data yang memiliki pola kompleks dan multidimensional [2], [4], [14]. Kemampuan jaringan dalam membangun representasi *internal* membuat model tetap stabil meskipun terdapat variasi data yang cukup tinggi.

Fenomena preferensi wisata yang bersifat subjektif dan sering kali tumpang tindih misalnya pengguna yang menyukai aktivitas alam namun juga menikmati wisata pantai menjadi salah satu tantangan bagi model. Beberapa kesalahan klasifikasi pada penelitian ini muncul pada sampel dengan karakteristik ganda atau ambigu, di mana pola preferensi tidak menunjukkan kecenderungan yang jelas. Situasi seperti ini konsisten dengan penelitian perilaku wisatawan berbasis ulasan dan data interaksi digital, yang menunjukkan bahwa faktor subjektif sering menghasilkan pola yang tidak stabil [1]. Meskipun demikian, kesalahan tersebut relatif kecil dan tidak memengaruhi performa keseluruhan model.

Kinerja MLP yang stabil juga tidak terlepas dari proses preprocessing yang dilakukan. Tahapan seperti normalisasi dan encoding berkontribusi pada peningkatan kualitas data sehingga jaringan saraf dapat mempelajari pola secara optimal. Pendekatan serupa juga digunakan pada penelitian klasifikasi kesehatan dan pendidikan, di mana *preprocessing* terbukti meningkatkan akurasi model secara signifikan [3], [5], [8]. Konsistensi ini memperkuat argumen bahwa MLP merupakan salah satu pendekatan deep learning yang paling fleksibel dan adaptif.

Selain itu, penelitian ini memberikan kontribusi pada pengembangan sistem rekomendasi wisata berbasis data. Dengan akurasi yang sangat tinggi, model berpotensi diterapkan untuk memprediksi preferensi destinasi pengguna secara personal. Pendekatan ini sejalan dengan perkembangan analitik pariwisata berbasis big data yang semakin banyak diterapkan oleh industri untuk meningkatkan pengalaman wisatawan [17]. Dengan demikian, MLP tidak hanya efektif secara teknis, tetapi juga memiliki nilai terapan yang tinggi pada sektor pariwisata digital.

Penelitian ini menyimpulkan bahwa algoritma *Multilayer Perceptron* (MLP) mampu memberikan performa yang sangat tinggi dalam mengklasifikasikan preferensi destinasi wisata antara gunung dan pantai. Dengan akurasi mencapai 99%, model berhasil mengidentifikasi kecenderungan pilihan wisata pengguna berdasarkan data demografis dan preferensi aktivitas. Hal ini menunjukkan bahwa MLP efektif dalam menangani relasi non-linear yang terdapat pada data tabular.

Selain itu, penelitian ini menegaskan pentingnya *preprocessing* dalam meningkatkan stabilitas dan akurasi model. Normalisasi, *encoding*, serta pembagian data latih dan uji terbukti memberikan dampak signifikan terhadap kemampuan generalisasi model. Kesalahan klasifikasi yang terjadi relatif kecil dan umumnya muncul pada kasus preferensi pengguna yang ambigu atau bersifat ganda.

Model yang dikembangkan memiliki potensi untuk digunakan dalam sistem rekomendasi destinasi wisata berbasis kecerdasan buatan, sehingga dapat membantu pengguna memilih destinasi yang lebih sesuai dengan karakteristik mereka. Untuk penelitian selanjutnya, model dapat diperluas untuk mencakup lebih banyak kategori destinasi wisata dan dapat digabungkan dengan teknik *deep learning* lainnya seperti CNN, LSTM, atau Transformer, terutama jika digunakan pada data teks ulasan, citra, atau data perilaku yang lebih kompleks.

REFERENCES

- [1] Y. A. Singgalen, "Analisis Perilaku Wisatawan Berdasarkan Data Ulasan di Website Tripadvisor Menggunakan CRISP-DM : Wisata Minat Khusus Pendakian Gunung Rinjani dan Gunung Bromo," vol. 4, no. 2, pp. 326–338, 2023, doi: 10.47065/josyc.v4i2.3042.
- [2] A. Tjahyanto and F. J. Atletiko, "Peningkatan Kinerja Pengklasifikasi Objek Bawah Laut Dengan Deep Learning Improved Undersea Object Classifier Performance With Deep Learning Neural Network," vol. 21, no. 3, pp. 753–760, 2022, doi: 10.30812/matrik.v21i3.1466.
- [3] N. Nurhadi, S. Defit, and G. W. Nurcahyo, "BULLETIN OF COMPUTER SCIENCE RESEARCH Model Deep Learning Berbasis Multilayer Perceptron untuk Identifikasi Demam Berdarah Dengue dan Tifus," vol. 5, no. 5, pp. 1095–1102, 2025, doi: 10.47065/bulletincsr.v5i5.754.
- [4] S. Ozsari *et al.*, "Deep Learning-Based Classification of Macrofungi : Comparative Analysis of Advanced Models for Accurate Fungi Identification," 2024.
- [5] E. Saputra and E. R. Susanto, "Implementation of Deep Learning with Multilayer Perceptron (MLP) for Heart Disease Prediction Using the SMOTE-ENN Technique," vol. 9, no. 3, pp. 1034–1041, 2025.

- [6] Jahnavi Paliwal, "Mountains vs Beaches Preferences Dataset," *Kaggle*, 2023. <https://www.kaggle.com/datasets/jahnavipaliwal/mountains-vs-beaches-preference>
- [7] V. No, M. Iqbal, Y. N. Dewi, and V. No, "Infotek : Jurnal Informatika dan Teknologi Optimalisasi Prediksi Dalam Kelulusan Berbasis Deep Learning : Perbandingan Kinerja Multi- Layer Perceptron dan Deep Neural Network Sekolah adalah proses belajar mendapatkan ilmu pengetahuan yang bermanfaat untuk," vol. 8, no. 2, pp. 630–641, 2025.
- [8] A. Li, X. Li, W. Li, X. Yu, M. Qi, and D. Li, "Application of Deep Learning on the Prognosis of Cutaneous Melanoma Based on Full Scan Pathology Images," vol. 2022, 2022.
- [9] P. Deep, L. Untuk, M. Dan, M. Gaya, and B. Siswa, "Pemanfaatan Deep Learning Untuk Mendeteksi Dan Menganalisis Gaya Belajar Siswa," vol. 1, no. 6, pp. 635–646, 2024.
- [10] I. N. Wahyuni *et al.*, "Preferensi Wisatawan Terhadap Destinasi Wisata Pantai Camplong Kabupaten Sampang," vol. 14, no. 1, pp. 51–60, 2021.
- [11] P. Jumlah, B. P. Dewani, M. S. Akbar, D. Statistika, F. Matematika, and S. Data, "Tanjung Perak Menggunakan Model Hybrid ARIMAX dan Deep Learning Neural Networks," vol. 2, no. March, 2019.
- [12] A. M. Toda *et al.*, "Analysing gamification elements in educational environments using an existing Gamification taxonomy," *Smart Learn. Environ.*, vol. 6, no. 1, pp. 1–15, 2019, doi: 10.1186/s40561-019-0106-1.
- [13] D. J. Bajpai and M. K. Hanawal, "A Survey of Early Exit Deep Neural Networks in NLP," 2025.
- [14] K. Hussain *et al.*, "Annals of GIS Analysing LULC transformations using remote sensing data : insights from a multilayer perceptron neural network approach a multilayer perceptron neural network approach," *Ann. GIS*, vol. 31, no. 3, pp. 473–500, 2025, doi: 10.1080/19475683.2024.2343399.
- [15] P. Dan, P. Pengunjung, T. Objek, W. Geopark, and K. Sukabumi, "Jurnal wilayah dan kota," vol. 06, no. 01, pp. 35–44.
- [16] M. A. Maulana, Rachma Siva Ainunnisa and G. W. Putri, "KLASIFIKASI GAMBAR TERHADAP IDENTIFIKASI POTENSI SUKABUMI DENGAN METODE DEEP LEARNING LOGISTIC REGRESSION SKRIPSI," 2024.
- [17] P. P. Disertasi and U. Udayana, "BIG DATA ANALYTICS FRAMEWORK BIG DATA ANALYTICS FRAMEWORK," pp. 1–86, 2021.