

## PENERAPAN DEEP LEARNING DALAM SISTEM INFORMASI GEOGRAFIS UNTUK ANALISIS DAMPAK PERUBAHAN IKLIM

Edi Iskandar<sup>1</sup>, Edy Prayitno<sup>2\*</sup>, Ivan Jaka Perdana<sup>3</sup>, Aloysius Agus Subagyo<sup>4</sup>

<sup>1,2,3,4</sup> Universitas Teknologi Digital Indonesia, \*Penulis Koresponden

e-mail: <sup>1</sup>edi\_iskandar@utdi.ac.id, <sup>2</sup>edy\_prayitno@utdi.ac.id, <sup>3</sup>ivanjaka@utdi.ac.id, <sup>4</sup>alagus@utdi.ac.id,

### ABSTRACT

*Climate change is increasingly contributing to the frequency and intensity of natural disasters, especially in archipelagic countries like Indonesia. This study aims to develop a predictive model for disaster risk levels using deep learning with climate and geographical variables. The simulated data includes variables such as average temperature, precipitation, humidity, wind speed, elevation, land cover type, and population density. The model was designed to classify disaster risk into four categories: no risk, low risk, moderate risk, and high risk. Data preprocessing involved normalization and an 80:20 train-test split. The model was trained using the Adam optimization algorithm with activation functions suitable for multi-class classification. Evaluation results show that the model can accurately predict disaster risk levels. This study demonstrates that simulated data can effectively support disaster risk prediction when observational data is limited. With further development using more comprehensive data, this model has the potential to be implemented in an early warning system to support decision-making in climate change mitigation in Indonesia.*

**Keywords:** climate change, deep learning, disaster risk, simulated data

### INTISARI

Perubahan iklim semakin meningkatkan frekuensi dan intensitas bencana alam, terutama di negara kepulauan seperti Indonesia. Penelitian ini bertujuan mengembangkan model prediksi tingkat risiko bencana berbasis deep learning dengan menggunakan variabel iklim dan geografis. Data simulasi yang digunakan mencakup suhu rata-rata, curah hujan, kelembapan, kecepatan angin, elevasi, tipe tutupan lahan, dan kepadatan penduduk. Model ini dikembangkan untuk mengklasifikasikan risiko bencana ke dalam empat kategori: tidak ada risiko, risiko rendah, risiko sedang, dan risiko tinggi. Proses pra-pemrosesan data mencakup normalisasi dan pembagian data latih dan data uji dengan rasio 80:20. Model dilatih menggunakan algoritma optimisasi Adam dengan fungsi aktivasi yang sesuai untuk klasifikasi multi-kelas. Evaluasi menunjukkan bahwa model mampu memprediksi tingkat risiko bencana dengan akurasi tinggi. Hasil penelitian ini menunjukkan bahwa data simulasi dapat mendukung prediksi risiko bencana ketika data observasi terbatas. Dengan pengembangan lebih lanjut menggunakan data yang lebih lengkap, model ini berpotensi diterapkan dalam sistem peringatan dini untuk mendukung pengambilan keputusan dalam mitigasi dampak perubahan iklim di Indonesia.

**Kata kunci:** data simulasi, deep learning, perubahan iklim, risiko bencana

### 1. PENDAHULUAN

Perubahan iklim menjadi isu global yang berdampak luas terhadap lingkungan dan kehidupan masyarakat (Hawa, Zakaria, Razman, & Majid, 2021). Di Indonesia, peningkatan suhu, curah hujan ekstrem, dan perubahan pola cuaca akibat perubahan iklim menimbulkan risiko terhadap kejadian bencana seperti banjir, tanah longsor, dan kekeringan (Sudarma & As-syakur, 2018). Menghadapi risiko tersebut, diperlukan sistem yang mampu menganalisis dan memprediksi tingkat risiko bencana di berbagai wilayah, sehingga langkah mitigasi dan adaptasi dapat dilakukan dengan lebih efektif (Moch, Suryawati, Tribhuwaneswari, & Teknik, 2022).

Pada penelitian ini, kami menerapkan pendekatan deep learning berbasis jaringan saraf tiruan untuk mengembangkan model prediksi tingkat risiko bencana berdasarkan variabel iklim dan lingkungan. Model ini memanfaatkan data simulasi yang dibuat untuk mewakili skenario perubahan iklim di Indonesia, dengan memperhitungkan variabel-variabel seperti suhu rata-rata, curah hujan, kelembapan, kecepatan angin, elevasi, tipe tutupan lahan, dan kepadatan penduduk. Penggunaan data simulasi menjadi pilihan yang relevan dalam penelitian

ini, mengingat keterbatasan akses data observasi yang lengkap dan konsisten untuk wilayah Indonesia dalam rentang waktu panjang (Anggraheni et al., 2022). Dengan data simulasi, kami dapat menguji berbagai skenario iklim dan mempelajari pola risiko bencana yang potensial di masa depan (Widiastutik & Bukhori, 2018).

Model deep learning dipilih karena kemampuannya dalam menangani data multidimensional dan menemukan pola kompleks di dalam data iklim (Somantri & Maharrani, 2022). Pendekatan ini memungkinkan model untuk mengenali pola-pola interaksi antara variabel iklim dan geografis yang dapat memengaruhi tingkat risiko bencana. Dalam penelitian ini, kami menggunakan arsitektur Neural Network yang terdiri dari beberapa lapisan tersembunyi untuk memprediksi kategori risiko bencana (dari risiko rendah hingga tinggi) pada setiap titik data spasial.


Proses pra-pemrosesan data, termasuk normalisasi dan pembagian data menjadi data latih dan data uji, dilakukan untuk memastikan bahwa model dapat belajar secara optimal dan memberikan prediksi yang akurat (Sari, Kurniawati, Prayitno, & Irfangi, 2019). Model kemudian dievaluasi menggunakan metrik-metrik seperti akurasi, precision, recall, dan F1-score untuk setiap tingkat risiko bencana (Rahayu & Farlina, 2021).

Penelitian ini berkontribusi pada pemahaman lebih lanjut mengenai dampak perubahan iklim terhadap risiko bencana di Indonesia, khususnya melalui pendekatan data simulasi dan analisis deep learning. Hasil penelitian ini diharapkan dapat menjadi dasar bagi pengambilan keputusan dalam mitigasi risiko bencana yang lebih efektif, serta sebagai model awal yang dapat dikembangkan lebih lanjut dengan data observasi di masa mendatang (Nugraha, 2018).

Penelitian ini bertujuan untuk mengembangkan model prediksi tingkat risiko bencana berbasis deep learning yang mampu menganalisis berbagai skenario perubahan iklim. Hasilnya diharapkan dapat mendukung pengambilan keputusan yang lebih efektif dalam mitigasi risiko bencana di Indonesia.

## 2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan berbasis data simulasi dan deep learning untuk mengembangkan model prediksi tingkat risiko bencana akibat perubahan iklim di Indonesia (Zulis Erwanto & Aditya Wiralatief Sanjaya, 2021). Tahapan penelitian mencakup pembuatan data simulasi, pra-pemrosesan data, pembangunan model, pelatihan dan evaluasi model, serta analisis hasil. Gambar 1 menyajikan diagram alir langkah-langkah penelitian.



Gambar 1. Diagram Alir Penelitian

### 2.1. Pembuatan Data Simulasi

Data simulasi dibuat untuk merepresentasikan kondisi iklim dan lingkungan di Indonesia, menggunakan variabel-variabel iklim dan geografis yang relevan (Nur, Juangga, Utami, & Wiyono, 2020). Variabel yang digunakan antara lain:

- Latitude dan Longitude: Koordinat geografis untuk merepresentasikan berbagai titik di Indonesia.
- Year: Rentang tahun dari 2000 hingga 2050 untuk memodelkan tren perubahan jangka panjang.
- Average Temperature: Suhu rata-rata tahunan yang meningkat secara bertahap untuk merefleksikan pemanasan global.
- Precipitation: Curah hujan tahunan berdasarkan distribusi normal untuk menunjukkan variasi wilayah tropis.
- Humidity: Kelembapan udara dalam persentase, bervariasi dalam rentang iklim tropis.
- Wind Speed: Kecepatan angin dalam m/s.
- Elevation: Ketinggian dari permukaan laut untuk mempertimbangkan kerentanan terhadap banjir.
- Land Cover Type: Jenis tutupan lahan (hutan, pertanian, permukiman).
- Population Density: Kepadatan penduduk per km<sup>2</sup>.
- Disaster Risk: Variabel target yang dikategorikan ke dalam empat tingkat risiko (0 = Tidak Ada Risiko, 1 = Risiko Rendah, 2 = Risiko Sedang, 3 = Risiko Tinggi).

Data simulasi ini disimpan dalam format CSV untuk memudahkan pemrosesan lebih lanjut.

## 2.2. Pra-Pemrosesan Data

Pra-pemrosesan data dilakukan untuk menyiapkan data sebelum digunakan dalam pelatihan model. Langkah-langkahnya meliputi:

- Normalisasi Data: Semua variabel numerik dinormalisasi menggunakan metode Min-Max Scaling untuk mengubah nilai menjadi rentang 0 hingga 1, yang membantu meningkatkan stabilitas pelatihan model (Polatgil, 2022).
- Pembagian Data: Dataset dibagi menjadi data latih (80%) dan data uji (20%) untuk melatih dan mengevaluasi model.

## 2.3. Arsitektur Model Deep Learning

Model deep learning yang digunakan dalam penelitian ini adalah jaringan saraf tiruan dengan beberapa lapisan tersembunyi (Ridwan, Yudo, Komunikasi, & Provinsi, 2020). Model ini dirancang menggunakan fungsi aktivasi ReLU di lapisan tersembunyi dan softmax di lapisan output.

- Fungsi Aktivasi ReLU: Fungsi aktivasi ReLU (Rectified Linear Unit) diterapkan untuk mengatasi permasalahan non-linear dalam data, dan dinyatakan sebagai berikut:

$$f(x) = \max(0, x)$$

Fungsi ini menjaga nilai positif, sementara nilai negatif dikonversi menjadi nol.

- Fungsi Aktivasi Softmax: Fungsi softmax digunakan pada lapisan output untuk menghasilkan probabilitas bagi setiap kelas risiko (Saputra, Rayes, & Nita, 2019). Rumus fungsi softmax adalah:

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}$$

di mana  $z$  adalah output dari lapisan sebelumnya, dan  $K$  adalah jumlah kelas yang diprediksi (dalam hal ini 4 kelas untuk kategori risiko bencana). Fungsi ini memungkinkan model untuk melakukan klasifikasi multi-kelas.

Model ini dilatih menggunakan algoritma Adam optimizer dengan learning rate 0.001, dan menggunakan fungsi loss sparse categorical crossentropy yang cocok untuk klasifikasi multi-kelas (Sun et al., 2021). Pelatihan model dilakukan selama 50 epoch dengan batch size 16.

## 2.4. Evaluasi Model

Model dievaluasi menggunakan data uji dengan beberapa metrik evaluasi utama (Hidayat, Hardiansyah, & Affandy, 2021):

- Akurasi: Mengukur persentase prediksi yang benar dari seluruh data uji.
- Precision, Recall, dan F1-Score: Metrik ini dihitung untuk setiap kelas risiko bencana untuk menilai kualitas prediksi model pada tiap kategori (Deborah Kurniawati, Edy Prayitno, Dini Fakta Sari, 2019).
- Confusion Matrix: Matriks kebingungan digunakan untuk menampilkan jumlah prediksi benar dan salah pada setiap kelas risiko, membantu mengidentifikasi kesalahan klasifikasi antar kelas.

Evaluasi model ini bertujuan untuk mengetahui sejauh mana model dapat memprediksi tingkat risiko bencana dengan tepat dan konsisten pada data uji. Model yang memiliki akurasi dan metrik evaluasi yang tinggi dianggap memenuhi syarat untuk digunakan sebagai alat bantu prediksi risiko bencana.

## 3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil dari proses pelatihan dan evaluasi model, diikuti dengan pembahasan mengenai performa model dalam memprediksi tingkat risiko bencana.

### 3.1 Hasil

Pada penelitian ini, model deep learning yang dikembangkan mampu memprediksi tingkat risiko bencana dengan akurasi yang tinggi. Evaluasi model dilakukan dengan metrik-metrik utama, seperti akurasi, precision, recall, F1-score, serta confusion matrix. Berikut adalah hasil evaluasi dari model yang telah dilatih menggunakan data uji.

Tabel 1 menunjukkan hasil classification report yang meliputi nilai precision, recall, dan F1-score untuk masing-masing kategori risiko bencana. Hasil ini memperlihatkan bahwa model memiliki performa yang baik pada kategori risiko rendah hingga sedang, dengan precision dan recall di atas 80% untuk setiap kelas tersebut.

**Tabel 1.** Classification Report untuk Setiap Kelas Risiko Bencana

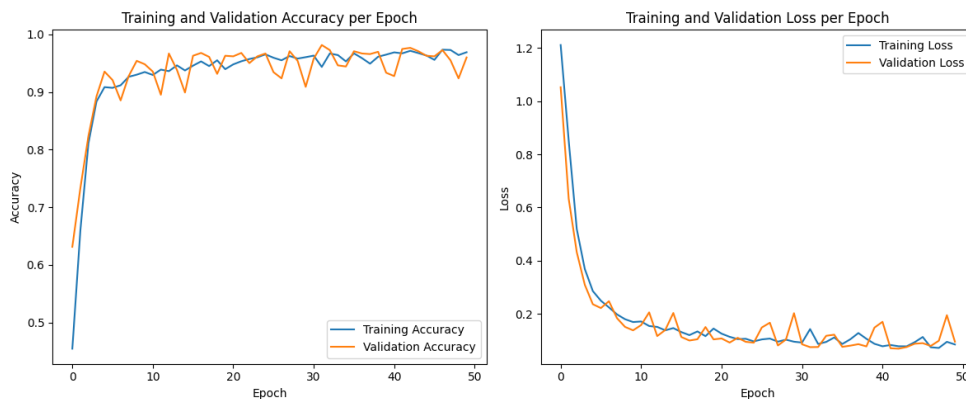
Kelas Risiko	Precision	Recall	F1-score	Jumlah Data
0 (Tidak Ada Risiko)	1.00	0.87	0.93	391
1 (Risiko Rendah)	0.81	0.86	0.83	253
2 (Risiko Sedang)	0.91	0.97	0.94	357
3 (Risiko Tinggi)	0.63	1.00	0.78	19

Confusion Matrix disajikan pada Tabel 2 untuk memberikan informasi lebih lanjut tentang distribusi prediksi model pada setiap kategori risiko. Matriks ini menunjukkan distribusi kesalahan prediksi antar kelas, terutama antara kategori risiko rendah dan sedang.

**Tabel 2.** Confusion Matrix untuk Kelas Risiko Bencana

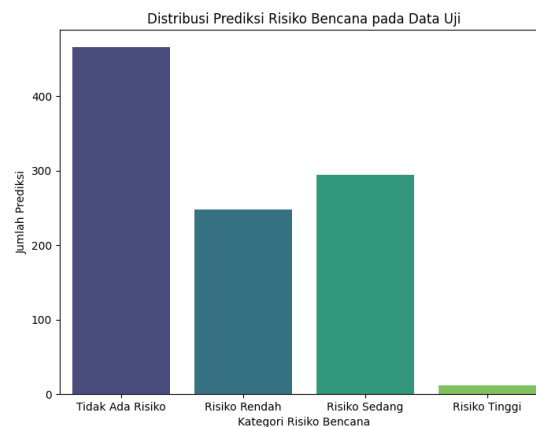
Kelas Aktual	Prediksi 0	Prediksi 1	Prediksi 2	Prediksi 3
0	341	50	0	0
1	0	217	36	0
2	0	0	346	11
3	0	0	0	19

Selain tabel, grafik yang menunjukkan akurasi dan loss selama pelatihan model disajikan pada Gambar 1. Grafik ini menunjukkan peningkatan akurasi dan penurunan loss seiring bertambahnya epoch, mengindikasikan bahwa model belajar dengan baik selama proses pelatihan.



**Gambar 1.** Grafik Akurasi dan Loss Selama Pelatihan Model

Distribusi prediksi model pada data uji disajikan pada Gambar 2. Grafik ini menampilkan jumlah prediksi model untuk setiap kategori risiko, memberikan gambaran tentang keseimbangan prediksi model pada setiap kelas risiko.



**Gambar 2.** Distribusi Prediksi Risiko Bencana pada Data Uji

### **3.2 Pembahasan**

Berdasarkan hasil evaluasi, model memiliki akurasi yang baik dalam memprediksi tingkat risiko bencana pada data uji, dengan akurasi total sebesar 90%. Kinerja model pada kategori risiko rendah hingga sedang menunjukkan precision dan recall yang tinggi, yang mengindikasikan bahwa model dapat mengenali pola risiko di tingkat ini dengan cukup andal. Hal ini juga mencerminkan bahwa variabel-variabel iklim dan geografis dalam data simulasi dapat membantu mengidentifikasi tingkat risiko bencana dengan baik.

Namun, performa model pada kategori risiko tinggi menunjukkan precision yang lebih rendah dibandingkan kategori lainnya, meskipun recall mencapai 100%. Hal ini berarti bahwa model dapat mengenali semua data aktual yang termasuk dalam kategori risiko tinggi, tetapi beberapa prediksi pada kategori ini mungkin salah mengklasifikasikan data dari kategori lain sebagai risiko tinggi. Salah satu penyebabnya adalah jumlah data yang lebih sedikit pada kelas risiko tinggi, yang mengakibatkan model kurang terlatih untuk pola khusus di kelas ini. Ketidakseimbangan data ini memengaruhi stabilitas prediksi model, terutama karena model lebih sulit mempelajari pola yang jarang muncul dalam data simulasi.

Penggunaan data simulasi dalam penelitian ini memungkinkan model untuk mempelajari berbagai variasi iklim dan geografis, tetapi tetap memiliki keterbatasan dalam merepresentasikan data nyata. Untuk penelitian lanjutan, disarankan untuk menggunakan teknik balancing data, seperti oversampling atau metode Synthetic Minority Over-sampling Technique (SMOTE), untuk meningkatkan jumlah data pada kelas risiko tinggi. Selain itu, integrasi data observasi nyata dapat digunakan untuk memvalidasi hasil model dan meningkatkan stabilitas prediksi pada semua kategori risiko.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa model berbasis deep learning dengan data simulasi dapat diandalkan untuk mendeteksi tingkat risiko bencana. Hasil ini mendukung penggunaan model ini dalam sistem peringatan dini untuk mitigasi bencana dan perencanaan wilayah, terutama di Indonesia, yang rentan terhadap dampak perubahan iklim.

## **4. KESIMPULAN**

Penelitian ini berhasil mengembangkan model prediksi berbasis deep learning untuk mengklasifikasikan tingkat risiko bencana di Indonesia dengan menggunakan variabel iklim dan geografis dari data simulasi. Model ini mencapai tingkat akurasi sebesar 90% pada data uji, dengan performa yang baik pada kategori risiko rendah hingga sedang. Hasil ini menunjukkan bahwa model berbasis jaringan saraf tiruan dapat diandalkan dalam memprediksi risiko bencana dan berpotensi diterapkan sebagai alat bantu dalam mitigasi bencana.

Penggunaan data simulasi dalam penelitian ini terbukti efektif, terutama ketika data observasi aktual terbatas. Namun, keterbatasan jumlah data pada kelas risiko tinggi mengakibatkan precision yang lebih rendah pada kategori ini. Untuk penelitian lanjutan, disarankan agar model divalidasi menggunakan data observasi nyata dari berbagai wilayah di Indonesia, yang dapat memperkaya pemahaman model terhadap pola risiko bencana di lingkungan nyata. Selain itu, metode balancing data seperti SMOTE dapat diterapkan untuk meningkatkan performa prediksi pada kategori risiko tinggi.

Secara keseluruhan, penelitian ini mendukung penggunaan model deep learning sebagai bagian dari sistem peringatan dini dan perencanaan mitigasi yang responsif terhadap perubahan iklim. Dengan pengembangan lebih lanjut menggunakan data observasi yang lebih komprehensif, model ini diharapkan dapat membantu dalam pengambilan keputusan yang lebih efektif dan mendukung kebijakan mitigasi perubahan iklim di Indonesia.

## **UCAPAN TERIMA KASIH**

Penulis mengucapkan terima kasih kepada semua dosen dan mahasiswa di Universitas Teknologi Digital Indonesia atas bantuan dan kontribusinya selama proses penelitian dan penyusunan artikel ini. Penelitian ini tidak akan berhasil tanpa bantuan dan kerja sama mereka. Penulis juga berterima kasih kepada panitia yang menyelenggarakan Seminar Nasional Aplikasi Sains & Teknologi (SNAST) 2024 di Universitas Akprind Indonesia, yang telah memberikan kesempatan kepada kami untuk mempresentasikan temuan penelitian kami. Seminar ini memberi kesempatan yang luar biasa untuk berbagi informasi dan memperluas pengetahuan dalam bidang sains dan teknologi.

## **DAFTAR PUSTAKA**

Anggraheni, E., Sutjningsih, D., Mulyono, B. H., Guswanto, Ningrum, I. A., & Yahya, D. M. (2022). Pengaruh Sebaran Spasial Hujan terhadap Pemilihan Metode Hujan Wilayah Berbasis Analisis Geospasial. *Jurnal Teknik Sumber Daya Air*, 2(2), 81–92. <https://doi.org/10.56860/jtsda.v2i2.41>

- Deborah Kurniawati, Edy Prayitno, Dini Fakta Sari, S. N. P. (2019). Sentiment analysis of twitter use on policy institution services using naive bayes classifier method. *Journal of International Conference Proceedings*, 2(1), 33.
- Hawa, N. N., Zakaria, S. Z. S., Razman, M. R., & Majid, N. A. (2021). Geography education for promoting sustainability in Indonesia. *Sustainability (Switzerland)*, 13(8), 1–15. <https://doi.org/10.3390/su13084340>
- Hidayat, E. Y., Hardiansyah, R. W., & Affandy, A. (2021). Analisis Sentimen Twitter untuk Menilai Opini Terhadap Perusahaan Publik Menggunakan Algoritma Deep Neural Network. *Jurnal Nasional Teknologi Dan Sistem Informasi*, 7(2), 108–118. <https://doi.org/10.25077/teknosi.v7i2.2021.108-118>
- Moch, S., Suryawati, I., Tribhuwaneswari, A. B., & Teknik, F. (2022). Jurnal Teknik WAKTU Volume 20 Nomor 02 – Juli 2022 – ISSN : 1412 : 1867 kabupaten / kota sebagai salah satu dasar pengambilan kebijakan perencanaan daerah secara optimal ( Shofwan , 2020 ), sehingga diharapkan dalam penelitian ini menghasilkan gambaran sp, 20, 129–138.
- Nugraha, A. L. (2018). Pemetaan Ancaman Banjir Kota Semarang Menggunakan Fuzzy Logic Dan Sig. *Teknik*, 39(1), 16. <https://doi.org/10.14710/teknik.v39i1.16524>
- Nur, A., Juangga, A., Utami, R., & Wiyono, A. (2020). Analisis Kecenderungan dan Perubahan Hujan Ekstrem Harian di Pulau Madura. *Jurnal Ilmu Lingkungan*, 18(1), 89–96. <https://doi.org/10.14710/jil.18.1.89-96>
- Polatgil, M. (2022). Investigation of the Effect of Normalization Methods on ANFIS Success: Forestfire and Diabets Datasets. *International Journal of Information Technology and Computer Science*, 14(1), 1–8. <https://doi.org/10.5815/ijitcs.2022.01.01>
- Rahayu, M. P., & Farlina, Y. (2021). Penerapan Metode Naive Bayes Dalam Prediksi Penyebab Kecelakaan Kerja Cv. Deka Utama. *Jurnal Larik: Ladang Artikel Ilmu Komputer*, 1(1), 21–26. <https://doi.org/10.31294/larik.v1i1.472>
- Ridwan, M., Yudo, A., Komunikasi, D., & Provinsi, S. (2020). Pengenalan Plat Kendaraan Bermotor Menggunakan Metode Gradien Karakter dan BPNN ( Backpropagation Neural Network ). *J-COSINE*, 4(2), 169–178.
- Saputra, M. A., Rayes, M. L., & Nita, I. (2019). Pemetaan Prediksi Sebaran Kerentanan Longsor Di Kecamatan Tawangmangu, Kabupaten Karanganyar Menggunakan Pendekatan Fuzzy Logic. *Jurnal Tanah Dan Sumberdaya Lahan*, 6(2), 1353–1359. <https://doi.org/10.21776/ub.jtstl.2019.006.2.16>
- Sari, D. F., Kurniawati, D., Prayitno, E., & Irfangi, I. (2019). Sentiment Analysis of Twitter Social Media to Online Transportation in Indonesia Using Naïve Bayes Classifier. *Journal of International Conference Proceedings*, 2(1). <https://doi.org/10.32535/jicp.v2i1.410>
- Somantri, O., & Maharrani, R. H. (2022). Metode Penilaian Kekuatan Gempa Menggunakan Model Feature Selection M5-Prime Dan Linear Regression. *Jurnal Informatika Polinema*, 9(1), 45–50. <https://doi.org/10.33795/jip.v9i1.989>
- Sudarma, I. M., & As-syakur, A. R. (2018). Dampak Perubahan Iklim Terhadap Sektor Pertanian Di Provinsi Bali. *SOCA: Jurnal Sosial Ekonomi Pertanian*, 12(1), 87. <https://doi.org/10.24843/soca.2018.v12.i01.p07>
- Sun, S., Zhang, Z., Huang, B., Lei, P., Su, J., Pan, S., & Cao, J. (2021). Sparse-softmax: A Simpler and Faster Alternative Softmax Transformation. *ArXiv Cornell University*. Retrieved from <http://arxiv.org/abs/2112.12433>
- Widiastutik, R., & Bukhori, I. (2018). Kajian Risiko Bencana Longsor Kecamatan Loano Kabupaten Purworejo. *Jurnal Pembangunan Wilayah & Kota*, 14(2), 109. <https://doi.org/10.14710/pwk.v14i2.19258>
- Zulis Erwanto, A. H., & Aditya Wiralatief Sanjaya. (2021). Identification And Prediction Of Coastline Changes In Banyuwangi. *ASTONJADRO: Jurnal Re Kayasa Sipil*, 10(2), 333–345.