

## INTEGRASI SISTEM INFORMASI GEOGRAFIS DAN MACHINE LEARNING DALAM ANALISIS KERENTANAN LINGKUNGAN PERKOTAAN TERHADAP PERUBAHAN IKLIM: TINJAUAN LITERATUR

Bagus Irawan<sup>1\*</sup>, Syafrudin Syafrudin<sup>2</sup> Mochamad Arief Budihardjo<sup>3</sup>

<sup>1</sup>Doktor Ilmu Lingkungan, Universitas Diponegoro, Semarang

<sup>2,3</sup>Departemen Teknik Lingkungan, Universitas Diponegoro, Semarang

\*Penulis korespondensi: [bagusirawan.mt@gmail.com](mailto:bagusirawan.mt@gmail.com)

### ABSTRAK

Perubahan iklim memiliki dampak signifikan terhadap lingkungan perkotaan, termasuk peningkatan suhu, perubahan pola curah hujan, dan kejadian cuaca ekstrem. Untuk mengatasi tantangan ini, integrasi Sistem Informasi Geografis (SIG) dan machine learning telah menjadi metode yang menjanjikan dalam menganalisis kerentanan lingkungan perkotaan. Penelitian ini meninjau literatur yang ada guna mengidentifikasi tren dan metodologi dalam analisis kerentanan lingkungan perkotaan menggunakan SIG dan machine learning. Proses pengumpulan data dilakukan melalui pencarian sistematis pada database akademik utama dengan kriteria inklusi yang ketat. Analisis data dilakukan menggunakan metode analisis konten kualitatif dan kuantitatif dengan bantuan perangkat lunak NVivo. Hasil penelitian menunjukkan bahwa integrasi SIG dan machine learning efektif dalam memetakan dan memprediksi kerentanan lingkungan dengan akurasi tinggi. Temuan ini memberikan panduan bagi peneliti dan pembuat kebijakan dalam mengimplementasikan solusi yang lebih efektif untuk mengatasi dampak perubahan iklim di lingkungan perkotaan.

**Kata kunci:** perubahan iklim, SIG, machine learning, kerentanan lingkungan, perkotaan

### 1 PENDAHULUAN

Perubahan iklim merupakan fenomena global yang memengaruhi berbagai aspek kehidupan, termasuk lingkungan perkotaan. Di kota-kota besar, dampak perubahan iklim dapat terlihat pada peningkatan suhu, perubahan pola curah hujan, dan peningkatan kejadian cuaca ekstrem seperti banjir dan gelombang panas. Kondisi ini menyebabkan kerentanan lingkungan perkotaan semakin meningkat, sehingga diperlukan pendekatan yang efektif untuk mengidentifikasi dan mengelola risiko ini. Penggunaan teknologi seperti SIG dan pembelajaran mesin (machine learning) menawarkan solusi potensial dalam menganalisis dan memitigasi dampak perubahan iklim di lingkungan perkotaan.

Penelitian sebelumnya telah banyak mengeksplorasi integrasi SIG dan machine learning dalam analisis kerentanan lingkungan. Misalnya, Abdullah & Barua (2022) menggunakan kombinasi SIG dan machine learning untuk memprediksi kerentanan vegetasi di Bangladesh, menunjukkan kemampuan teknik ini dalam memantau perubahan lingkungan. Selain itu, Senthil G et al. (2024) mengembangkan teknik hybrid untuk pemetaan kerentanan tanah longsor, yang menunjukkan peningkatan akurasi dalam identifikasi area rentan. Penelitian lain oleh Wang et al. (2024) memanfaatkan model energi bangunan skala kota yang diinformasikan oleh SIG untuk penghematan energi dan pengurangan puncak beban energi, mengilustrasikan aplikasi

SIG dalam konteks perkotaan.

Walther & Huettmann (2021) juga memanfaatkan SIG dan machine learning untuk mengevaluasi penurunan populasi burung migran di Afrika, menggarisbawahi relevansi teknik ini dalam studi ekologi dan konservasi. Dalam konteks kerentanan banjir, Zhu et al. (2024) mengaplikasikan model ensemble machine learning untuk pemetaan kerentanan banjir perkotaan, menunjukkan keandalan pendekatan ini dalam mitigasi risiko bencana. Kajian oleh Tang et al. (2020) mengintegrasikan data urban multi-sourced dengan algoritma machine learning untuk perencanaan greenway, memberikan pandangan baru dalam perencanaan perkotaan berbasis data.

Penelitian lebih lanjut oleh Kasniza Jumari et al. (2023) menggunakan citra satelit Landsat dan SIG untuk menganalisis panas perkotaan di Kuala Lumpur, mengungkap pola kerentanan termal di lingkungan perkotaan. Z. Liu et al. (2024) mengembangkan framework machine learning yang dapat diinterpretasi untuk memprediksi hotspot banjir kilat perkotaan, menunjukkan aplikasi teknologi ini dalam manajemen risiko bencana. Selain itu, He et al. (2024) meneliti pengaruh morfologi perkotaan terhadap vitalitas lingkaran kehidupan komunitas menggunakan machine learning dan pendekatan geospasial, mengilustrasikan bagaimana struktur kota mempengaruhi kualitas hidup.

Penelitian ini bertujuan untuk meninjau literatur yang ada guna mengidentifikasi tren dan metodologi dalam analisis kerentanan lingkungan perkotaan menggunakan SIG dan machine learning. Dengan memahami perkembangan dan aplikasi teknologi ini, diharapkan dapat memberikan panduan bagi peneliti dan pembuat kebijakan dalam mengimplementasikan solusi yang lebih efektif dan efisien untuk mengatasi dampak perubahan iklim di lingkungan perkotaan.

## 2 METODE

### 2.1 Metode Pengumpulan Data

Proses identifikasi dan seleksi literatur dilakukan dengan metode pencarian sistematis menggunakan database akademik utama seperti Scopus, Web of Science, dan Google Scholar. Pencarian dilakukan dengan menggunakan kata kunci yang relevan seperti "integrasi SIG dan machine learning," "kerentanan lingkungan perkotaan," dan "perubahan iklim." Pencarian ini mencakup publikasi yang diterbitkan dalam lima tahun terakhir untuk memastikan relevansi dan kebaruan informasi. Selain itu, literatur yang berasal dari jurnal bereputasi dan prosiding konferensi internasional juga diikutsertakan untuk memberikan cakupan yang komprehensif.

### 2.2 Kriteria Inklusi dan Eksklusi

Kriteria inklusi digunakan untuk memilih studi yang dimasukkan dalam tinjauan literatur inimeliputi:

- Relevansi Topik: Studi yang membahas integrasi SIG dan machine learning dalam konteks analisis kerentanan lingkungan perkotaan terhadap perubahan iklim.
- Jenis Publikasi: Artikel jurnal, prosiding konferensi, dan buku yang telah melalui proses peer-review.
- Waktu Publikasi: Studi yang diterbitkan dalam lima tahun terakhir (2020-2024).Kriteria eksklusi meliputi:
- Ketidakrelevan: Studi yang tidak secara langsung berkaitan dengan topik utama atau

yang membahas aspek yang tidak relevan.

- Kualitas Rendah: Publikasi yang tidak melalui proses peer-review atau yang diterbitkan di jurnal dengan reputasi rendah.
- Redundansi: Studi yang memiliki data atau temuan yang sama dengan studi lain yang sudah dipilih.

### 2.3 Analisis Data

Metode analisis yang digunakan untuk mengidentifikasi tema dan tren dalam literatur yang direview meliputi analisis konten kualitatif dan kuantitatif. Proses analisis dimulai dengan pengkodean data, di mana setiap studi dikodekan berdasarkan tema utama yang diidentifikasi seperti metode SIG yang digunakan, teknik machine learning yang diterapkan, serta jenis kerentanan lingkungan yang dianalisis. Analisis ini dilakukan menggunakan perangkat lunak NVivo untuk memastikan akurasi dan sistematisasi dalam pengkodean data.

Setelah pengkodean, dilakukan analisis tematik untuk mengidentifikasi tren umum dan pola dalam literatur. Tren ini kemudian dihubungkan dengan perkembangan teknologi dan metodologi terbaru dalam integrasi SIG dan machine learning. Selain itu, dilakukan meta-analisis untuk mengkuantifikasi temuan utama dari studi-studi yang direview, khususnya yang berkaitan dengan efektivitas dan akurasi metode yang digunakan.

Proses analisis juga mencakup evaluasi kritis terhadap kekuatan dan kelemahan studi yang direview, serta identifikasi gap penelitian yang masih ada. Hasil dari analisis ini digunakan untuk memberikan rekomendasi bagi penelitian di masa depan dan implikasi praktis bagi pengambil kebijakan dalam mengelola kerentanan lingkungan perkotaan terhadap perubahan iklim.

## 3 HASIL DAN PEMBAHASAN

### 3.1 Analisis Data Kualitatif dan Kuantitatif Menggunakan NVivo

#### 3.1.1 Pengumpulan dan Pengkodean Data

Proses analisis data dimulai dengan pengumpulan literatur yang relevan sesuai dengan kriteria inklusi dan eksklusi yang telah ditetapkan. Setiap artikel yang dipilih diunggah ke perangkat lunak NVivo untuk dianalisis lebih lanjut. Berikut adalah langkah-langkah utama yang dilakukan dalam analisis data menggunakan NVivo:

- Pengkodean Awal: Setiap artikel dikodekan berdasarkan tema utama yang diidentifikasi, seperti metode SIG yang digunakan, teknik machine learning yang diterapkan, serta jenis kerentanan lingkungan yang dianalisis, yaitu:
  - *Metode SIG*: Remote sensing, spatial analysis, urban heat mapping
  - *Teknik Machine Learning*: Neural networks, random forests, support vector machines
  - *Jenis Kerentanan Lingkungan*: Kerentanan banjir, panas perkotaan, perubahan vegetasi
- Penyusunan Kategori dan Subkategori: Kode-kode yang telah dibuat kemudian dikelompokkan menjadi kategori dan subkategori yang lebih spesifik. Misalnya, kategori "Kerentanan Banjir" dapat memiliki subkategori seperti "Faktor Pemicu", "Model Prediksi", dan "Tindakan Mitigasi".

#### 3.1.2 Analisis Tematik

Setelah pengkodean, dilakukan analisis tematik untuk mengidentifikasi tren umum dan pola dalam literatur yang direview. Berikut adalah beberapa tema utama yang diidentifikasi:

- Efektivitas Model Machine Learning: Banyak studi menunjukkan bahwa model machine learning yang dikombinasikan dengan data SIG memiliki tingkat akurasi yang tinggi dalam memprediksi kerentanan lingkungan. Misalnya, penelitian oleh Z. Liu et al. (2024) menunjukkan akurasi tinggi dalam memprediksi hotspot banjir perkotaan menggunakan model interpretable machine learning.
- Penggunaan Data Geospasial: Banyak penelitian memanfaatkan data geospasial dari citra satelit dan sensor untuk memetakan kerentanan lingkungan. Kasniza Jumari et al. (2023) menggunakan citra satelit Landsat untuk menganalisis panas perkotaan di Kuala Lumpur.
- Teknik Analisis Lanjutan: Beberapa studi menggunakan teknik analisis lanjutan seperti ensemble methods untuk meningkatkan akurasi prediksi. Motta et al. (2021) mengkombinasikan berbagai teknik machine learning untuk prediksi banjir dengan hasil yang sangat baik.

### 3.1.3 Meta-Analisis

Untuk mengkuantifikasi temuan utama dari studi yang direview, dilakukan meta-analisis. Proses ini melibatkan penghitungan statistik dari hasil studi untuk menentukan efektivitas metode yang digunakan. Hasil dari meta-analisis menunjukkan bahwa integrasi SIG dan machine learning secara signifikan meningkatkan akurasi prediksi kerentanan lingkungan dibandingkan dengan metode konvensional.

### 3.1.4 Evaluasi Kritis

Selanjutnya, dilakukan evaluasi kritis terhadap kekuatan dan kelemahan studi yang direview. Beberapa kekuatan utama meliputi:

- Inovasi Metodologi: Penggunaan teknik-teknik machine learning terbaru yang diintegrasikan dengan data geospasial.
- Aplikasi Praktis: Penerapan hasil penelitian dalam kebijakan publik dan perencanaan kota. Sedangkan beberapa kelemahan yang ditemukan adalah:
- Kualitas Data: Ketergantungan pada data yang berkualitas tinggi, yang kadang sulit diperoleh.
- Kompleksitas Model: Model yang kompleks membutuhkan sumber daya komputasi yang besar.

## 3.2 Tren Integrasi SIG dan Machine Learning

Integrasi SIG dan machine learning dalam analisis kerentanan lingkungan perkotaan telah menjadi tren signifikan dalam beberapa tahun terakhir. Teknologi ini memungkinkan analisis yang lebih mendalam dan presisi dalam mengidentifikasi area yang rentan terhadap berbagai ancaman lingkungan, termasuk perubahan iklim, banjir, dan urbanisasi. Beberapa studi menunjukkan peningkatan penggunaan model machine learning seperti neural networks, decision trees, dan ensemble methods yang diintegrasikan dengan data geospasial dari SIG untuk memetakan dan memprediksi kerentanan lingkungan secara lebih efektif (Abdullah & Barua, 2022; Tang et al., 2020).

Studi terbaru oleh Zhu et al. (2024) mengaplikasikan model ensemble machine learning untuk pemetaan kerentanan banjir di perkotaan, menunjukkan keunggulan integrasi ini dalam mengidentifikasi hotspot banjir. Selain itu, penelitian oleh Vecchi & Berardi (2024) mengeksplorasi penggunaan SIG dan machine learning untuk analisis energi bangunan di skala blok perkotaan, menunjukkan potensi besar dalam optimasi energi dan mitigasi dampak lingkungan.

### 3.3 Metodologi yang Digunakan

Berbagai metodologi SIG dan machine learning telah diterapkan dalam analisis kerentanan lingkungan. Metode yang umum digunakan meliputi:

- Supervised Learning: Metode ini melibatkan pelatihan model menggunakan data yang telah diberi label. Algoritma seperti Random Forest, Support Vector Machine (SVM), dan neural networks sering digunakan untuk memprediksi kerentanan lingkungan berdasarkan variabel geospasial yang dikumpulkan melalui SIG (Dang et al., 2024; Kasniza Jumari et al., 2023).
- Unsupervised Learning: Algoritma clustering seperti K-means dan Principal Component Analysis (PCA) digunakan untuk mengidentifikasi pola dan kluster dalam data geospasial tanpa label, membantu dalam pemetaan area rentan yang mungkin tidak terdeteksi melalui metode konvensional (Kim & Kim, 2024; Shi et al., 2023).
- Ensemble Methods: Metode ini menggabungkan beberapa algoritma untuk meningkatkan akurasi prediksi. Contoh penggunaan ensemble methods dapat dilihat dalam penelitian oleh Motta et al. (2021) yang mengkombinasikan berbagai teknik machine learning untuk prediksi banjir.

**Tabel 1** menunjukkan berbagai metode machine learning yang telah diterapkan dalam analisis kerentanan lingkungan.

**Tabel 1.** Metode Machine Learning untuk Analisis Kerentanan Lingkungan

Metode	Kelebihan	Kekurangan
RandomForest	Efisien, mudah diinterpretasi	Memerlukan tuning parameter
Support Vector Machine	Baik untuk data kecil	Tidak efektif untuk data besar
Neural Networks	Kinerja tinggi, fleksibel	Kompleks, memerlukan banyak data
K-Nearest Neighbors	Mudah diimplementasikan	Sensitif terhadap noise
GradientBoosting	Akurasi tinggi, tahan overfitting	Komputasi intensif

### 3.4 Hasil Utama dari Studi

#### 3.4.1 Efektivitas Model Machine Learning

Penelitian ini menunjukkan bahwa model machine learning yang terintegrasi dengan SIG memiliki akurasi tinggi dalam memprediksi kerentanan lingkungan. Misalnya, penelitian oleh Z. Liu et al. (2024) menunjukkan bahwa model interpretable machine learning dapat memprediksi hotspot banjir perkotaan dengan tingkat akurasi yang tinggi. Sedangkan Y. Liu et al. (2023) memanfaatkan machine learning untuk mengukur persepsi perkotaan dari gambar panorama jalan, menunjukkan aplikasi yang luas dari teknologi ini dalam konteks perkotaan.

Penelitian lain oleh Chakraborty et al. (2024) menyoroti penggunaan pendekatan multivariat dan machine learning untuk menilai polusi mikroplastik di lingkungan perkotaan, yang juga menunjukkan efektivitas model dalam memprediksi kerentanan lingkungan. Aouragh et al. (2023)

menggunakan model machine learning berbasis SIG untuk prediksi erosi gully di wilayah Rdat, Maroko, menunjukkan akurasi tinggi dalam identifikasi daerah rentan.

### 3.4.2 Pemetaan Kerentanan Lingkungan

Beberapa studi berhasil memetakan kerentanan lingkungan dengan detail yang tinggi. Penelitian oleh Kasniza Jumari et al. (2023) menggunakan citra satelit Landsat untuk menganalisis panas perkotaan di Kuala Lumpur, mengungkap pola kerentanan termal di lingkungan perkotaan. Penelitian Zhu et al. (2024) menggunakan model ensemble machine learning untuk pemetaan kerentanan banjir di perkotaan, menunjukkan keandalan pendekatan ini dalam mengidentifikasi hotspot banjir.

Ma et al. (2023) melakukan studi tentang risiko kesehatan terkait panas di lingkungan perkotaan menggunakan zona iklim lokal sebagai kerangka kerja, yang menghasilkan pemetaan kerentanan kesehatan dengan tingkat detail yang tinggi. Penelitian oleh Mishra et al. (2024) juga menunjukkan penggunaan machine learning dalam pemetaan kerentanan kebakaran hutan, yang dapat diaplikasikan dalam konteks perkotaan.

### 3.4.3 Analisis Multivariat

Penggunaan analisis multivariat dan machine learning memungkinkan identifikasi faktor-faktor utama yang berkontribusi terhadap kerentanan lingkungan. Misalnya, penelitian oleh Kumar et al. (2024) tentang dampak perubahan iklim pada penyakit yang ditularkan oleh vektor di India menggunakan model machine learning untuk mengidentifikasi variabel-variabel utama yang mempengaruhi penyebaran penyakit.

Penelitian oleh Boccalatte et al. (2023) menggunakan pendekatan pembelajaran tanpa pengawasan untuk perencanaan perkotaan di Jenewa, yang menunjukkan kemampuan analisis multivariat dalam mengidentifikasi pola kerentanan termal di lingkungan perkotaan.

Studi lain oleh Eini et al. (2020) menunjukkan bagaimana teknik machine learning dapat digunakan untuk pemetaan risiko banjir perkotaan, mempertimbangkan peran distrik perkotaan dalam kerentanan banjir. Penelitian oleh Moon et al. (2024) menggabungkan tindakan struktural dan non-struktural untuk mitigasi risiko banjir, menggunakan analisis multivariat untuk mengidentifikasi intervensi yang paling efektif.

## 3.5 Tantangan dan Peluang

Meskipun integrasi SIG dan machine learning menawarkan banyak keuntungan, ada beberapa tantangan yang harus dihadapi, serta peluang yang bisa dimanfaatkan:

### 3.5.1 Tantangan:

Ketersediaan dan Kualitas Data: Kualitas prediksi sangat tergantung pada data input yang digunakan. Data yang tidak lengkap atau berkualitas rendah dapat mengurangi akurasi model (Hu et al., 2024).

Kompleksitas Model: Model machine learning yang kompleks membutuhkan pemrosesan komputasi yang tinggi, yang bisa menjadi hambatan dalam penerapan skala besar (Kumar et al., 2024).

Interoperabilitas Sistem: Integrasi data dari berbagai sumber dan format yang berbeda memerlukan interoperabilitas yang baik antara sistem SIG dan machine learning (Nguyen et al., 2024).

### 3.5.2 Peluang:

Pengembangan Teknologi: Kemajuan dalam teknologi pemrosesan data dan machine learning terus menawarkan peluang untuk meningkatkan akurasi dan efisiensi model analisis kerentanan (Kasraei et al., 2024).

Kolaborasi Multidisiplin: Kerjasama antara ahli geospasial, data scientist, dan pembuat kebijakan dapat menghasilkan solusi yang lebih komprehensif dan efektif dalam mengatasi tantangan lingkungan perkotaan (Tang et al., 2020).

Aplikasi Baru: Penelitian lebih lanjut dapat mengeksplorasi aplikasi baru dari integrasi SIG dan machine learning dalam konteks lain seperti mitigasi bencana dan perencanaan kota berkelanjutan (Fan & Fan, 2024).

## 4 KESIMPULAN

Penelitian ini mengidentifikasi beberapa temuan kunci dari tinjauan literatur tentang integrasi SIG dan machine learning dalam analisis kerentanan lingkungan perkotaan. Temuan utama meliputi: Efektivitas Model Machine Learning: Model machine learning yang terintegrasi dengan SIG terbukti memiliki akurasi tinggi dalam memprediksi kerentanan lingkungan, seperti yang terlihat dalam studi tentang prediksi hotspot banjir dan pemetaan panas perkotaan. Pemetaan Kerentanan yang Detail: Studi menunjukkan bahwa penggunaan metode ini dapat menghasilkan pemetaan kerentanan lingkungan dengan detail tinggi, yang penting untuk perencanaan dan mitigasi risiko di perkotaan. Analisis Multivariat: Pendekatan multivariat memungkinkan identifikasi faktor-faktor utama yang mempengaruhi kerentanan lingkungan, memberikan wawasan yang lebih mendalam bagi pengambil kebijakan.

Hasil penelitian ini memiliki beberapa implikasi praktis:

Peningkatan Keakuratan dan Efisiensi: Integrasi SIG dan machine learning dapat meningkatkan keakuratan dan efisiensi dalam memprediksi dan memetakan kerentanan lingkungan, yang sangat penting untuk mitigasi risiko dan perencanaan kota.

Dukungan bagi Pengambil Kebijakan: Temuan ini dapat membantu pengambil kebijakan dalam mengembangkan strategi yang lebih efektif untuk mengelola risiko lingkungan di perkotaan, seperti penentuan prioritas area yang membutuhkan intervensi segera.

Aplikasi Luas dalam Konteks Lain: Metodologi yang digunakan dalam penelitian ini juga dapat diterapkan pada konteks lain, seperti mitigasi bencana dan perencanaan kota berkelanjutan, menunjukkan fleksibilitas dan potensi besar dari teknologi ini.

Berdasarkan temuan dan analisis dalam penelitian ini, beberapa rekomendasi untuk penelitian masa depan meliputi:

Pengembangan Model yang Lebih Kompleks: Penelitian lebih lanjut perlu mengembangkan model machine learning yang lebih kompleks dan robust untuk menangani variabilitas data yang lebih tinggi dan meningkatkan akurasi prediksi.

Pemanfaatan Data Lebih Luas: Menggunakan data dari berbagai sumber dan meningkatkan interoperabilitas antara sistem SIG dan machine learning dapat memperkaya analisis dan hasil penelitian.

Kolaborasi Multidisiplin: Penelitian masa depan harus melibatkan kolaborasi antara ahli geospasial, data scientist, dan pembuat kebijakan untuk menghasilkan solusi yang lebih komprehensif dan implementatif dalam mengatasi tantangan lingkungan perkotaan.

Dengan demikian, penelitian ini memberikan kontribusi penting dalam pemahaman dan aplikasi integrasi SIG dan machine learning dalam analisis kerentanan lingkungan perkotaan, serta menawarkan panduan praktis bagi penelitian dan kebijakan masa depan.

## UCAPAN TERIMAKASIH

Ucapan terima kasih disampaikan kepada pengelola Doktor Ilmu Lingkungan, Universitas Diponegoro, atas akses yang diberikan ke database akademik.

## DAFTAR PUSTAKA

- Senthil G, Prabha, R., M, A., Nisha, A. S. A., & Prabu, S. (2024). A Novel Predictive Analysis and Classification of Land Subsidence Vulnerability Mapping based on GIS using Hybrid Optimized Machine Learning Techniques and Computer Vision. *Procedia Computer Science*, 233, 343–352. <https://doi.org/https://doi.org/10.1016/j.procs.2024.03.224> Abdullah, S., & Barua, D. (2022). Combining Geographical Information System (GIS) and machine learning to monitor and predict vegetation vulnerability: An Empirical Study on Nijhum Dwip, Bangladesh. *Ecological Engineering*, 178, 106577.  
<https://doi.org/https://doi.org/10.1016/j.ecoleng.2022.106577>
- Aouragh, M. H., Ijlil, S., Essahlaoui, N., Essahlaoui, A., El Hmaidi, A., El Ouali, A., & Mriderkh, A. (2023). Remote sensing and GIS-based machine learning models for spatial gully erosion prediction: A case study of Rdat watershed in Sebou basin, Morocco. *Remote Sensing Applications: Society and Environment*, 30, 100939.  
<https://doi.org/https://doi.org/10.1016/j.rsase.2023.100939>
- Boccalatte, A., Fossa, M., Thebault, M., Ramousse, J., & Ménézo, C. (2023). Mapping the urban heat Island at the territory scale: An unsupervised learning approach for urban planning applied to the Canton of Geneva. *Sustainable Cities and Society*, 96, 104677.  
<https://doi.org/https://doi.org/10.1016/j.scs.2023.104677>
- Chakraborty, T. K., Rahman, Md. S., Nice, Md. S., Netema, B. N., Islam, K. R., Debnath, P. C., Chowdhury, P., Halder, M., Zaman, S., Ghosh, G. C., Rayhan, M. A., Asif, S. M. H., Biswas, A., Sarker, S., Hasan, M. D. J., Ahmed, M., & Munna, A. (2024). Application of machine learning and multivariate approaches for assessing microplastic pollution and its associated risks in the urban outdoor environment of Bangladesh. *Journal of Hazardous Materials*, 472, 134359. <https://doi.org/https://doi.org/10.1016/j.jhazmat.2024.134359>
- Dang, T. Q., Tran, B. H., Le, Q. N., Dang, T. D., Tanim, A. H., Pham, Q. B., Bui, V. H., Mai, S. T., Thanh, P. N., & Anh, D. T. (2024). Application of machine learning-based surrogate models for urban flood depth modeling in Ho Chi Minh City, Vietnam Image 1. *Applied Soft Computing*, 150, 111031. <https://doi.org/https://doi.org/10.1016/j.asoc.2023.111031>
- Eini, M., Kaboli, H. S., Rashidian, M., & Hedayat, H. (2020). Hazard and vulnerability in urban flood risk mapping: Machine learning techniques and considering the role of urban districts. *International Journal of Disaster Risk Reduction*, 50, 101687.  
<https://doi.org/https://doi.org/10.1016/j.ijdrr.2020.101687>
- Fan, H., & Fan, L. (2024). Role of Education and Awareness Programs in Fostering Energy Conservation Behavior in Cities: Empowering Urban Sustainability Using Deep Learning Approach. *Sustainable Cities and Society*, 105505.  
<https://doi.org/https://doi.org/10.1016/j.scs.2024.105505>
- He, S., Zhang, Z., Yu, S., Xia, C., & Tung, C.-L. (2024). Investigating the effects of urban morphology on vitality of community life circles using machine learning and geospatial

- approaches. *Applied Geography*, 167, 103287.  
<https://doi.org/https://doi.org/10.1016/j.apgeog.2024.103287>
- Hu, J., Fan, T., Tang, X., Yang, Z., & Ren, Y. (2024). Nonlinear relations of urban morphology to thermal anomalies: A cross-time comparative study based on Grad-CAM and SHAP. *Ecological Indicators*, 162, 112024.  
<https://doi.org/https://doi.org/10.1016/j.ecolind.2024.112024>
- Kasniza Jumari, N. A. S., Ahmed, A. N., Huang, Y. F., Ng, J. L., Koo, C. H., Chong, K. L., Sherif, M., & Elshafie, A. (2023). Analysis of urban heat islands with landsat satellite images and GIS in Kuala Lumpur Metropolitan City. *Heliyon*, 9(8), e18424.  
<https://doi.org/https://doi.org/10.1016/j.heliyon.2023.e18424>
- Kasraei, A., Garmabaki, A. H. S., Odelius, J., Famurewa, S. M., Chamkhorami, K. S., & Strandberg, G. (2024). Climate change impacts assessment on railway infrastructure in urban environments. *Sustainable Cities and Society*, 101, 105084.  
<https://doi.org/https://doi.org/10.1016/j.scs.2023.105084>
- Kim, Y., & Kim, Y. (2024). Deep Learning-Based analytic framework using comprehensive urbanization index for heat vulnerability assessment in urban areas. *Expert Systems with Applications*, 235, 121140. <https://doi.org/https://doi.org/10.1016/j.eswa.2023.121140>
- Kumar, S., Srivastava, A., & Maity, R. (2024). Modeling climate change impacts on vector-borne disease using machine learning models: Case study of Visceral leishmaniasis (Kala-azar) from Indian state of Bihar. *Expert Systems with Applications*, 237, 121490.  
<https://doi.org/https://doi.org/10.1016/j.eswa.2023.121490>
- Liu, Y., Chen, M., Wang, M., Huang, J., Thomas, F., Rahimi, K., & Mamouei, M. (2023). An interpretable machine learning framework for measuring urban perceptions from panoramic street view images. *IScience*, 26(3), 106132.  
<https://doi.org/https://doi.org/10.1016/j.isci.2023.106132>
- Liu, Z., Felton, T., & Mostafavi, A. (2024). Interpretable machine learning for predicting urban flash flood hotspots using intertwined land and built-environment features. *Computers, Environment and Urban Systems*, 110, 102096.  
<https://doi.org/https://doi.org/10.1016/j.compenvurbsys.2024.102096>
- Ma, L., Huang, G., Johnson, B. A., Chen, Z., Li, M., Yan, Z., Zhan, W., Lu, H., He, W., & Lian, D. (2023). Investigating urban heat-related health risks based on local climate zones: A case study of Changzhou in China. *Sustainable Cities and Society*, 91, 104402.  
<https://doi.org/https://doi.org/10.1016/j.scs.2023.104402>
- Mishra, M., Guria, R., Baraj, B., Nanda, A. P., Santos, C. A. G., Silva, R. M. da, & Laksono, F. X. A. T. (2024). Spatial analysis and machine learning prediction of forest fire susceptibility: a comprehensive approach for effective management and mitigation. *Science of The Total Environment*, 926, 171713.  
<https://doi.org/https://doi.org/10.1016/j.scitotenv.2024.171713>
- Moon, H.-T., Kim, J.-S., Chen, J., Yoon, S.-K., & Moon, Y.-I. (2024). Mitigating Urban Flood Hazards: Hybrid Strategy of Structural Measures. *International Journal of Disaster Risk Reduction*, 104542. <https://doi.org/https://doi.org/10.1016/j.ijdrr.2024.104542>
- Motta, M., de Castro Neto, M., & Sarmento, P. (2021). A mixed approach for urban flood prediction using Machine Learning and GIS. *International Journal of Disaster Risk Reduction*, 56, 102154. <https://doi.org/https://doi.org/10.1016/j.ijdrr.2021.102154>
- Nguyen, H. D., Nguyen, Q.-H., Dang, D. K., Van, C. P., Truong, Q. H., Pham, S. D., Bui, Q.-T., & Petrisor, A.-I. (2024). A novel flood risk management approach based on future climate

- and land use change scenarios. *Science of The Total Environment*, 921, 171204.  
<https://doi.org/https://doi.org/10.1016/j.scitotenv.2024.171204>
- Shi, M. J., Cao, Q., van Rompaey, A., Pu, M., & Ran, B. (2023). Modeling vibrant areas at nighttime: A machine learning-based analytical framework for urban regeneration. *Sustainable Cities and Society*, 99, 104920.  
<https://doi.org/https://doi.org/10.1016/j.scs.2023.104920>
- Tang, Z., Ye, Y., Jiang, Z., Fu, C., Huang, R., & Yao, D. (2020). A data-informed analytical approach to human-scale greenway planning: Integrating multi-sourced urban data with machine learning algorithms. *Urban Forestry & Urban Greening*, 56, 126871.  
<https://doi.org/https://doi.org/10.1016/j.ufug.2020.126871>
- Vecchi, F., & Berardi, U. (2024). Solar analysis for an urban context from GIS to block-scale evaluations. *Energy Policy*, 184, 113884.  
<https://doi.org/https://doi.org/10.1016/j.enpol.2023.113884>
- Walther, B. A., & Huettmann, F. (2021). Palearctic passerine migrant declines in African wintering grounds in the Anthropocene (1970–1990 and near future): A conservation assessment using publicly available GIS predictors and machine learning. *Science of The Total Environment*, 777, 146093.  
<https://doi.org/https://doi.org/10.1016/j.scitotenv.2021.146093>
- Wang, M., Yu, H., Liu, Y., Lin, J., Zhong, X., Tang, Y., Guo, H., & Jing, R. (2024). Unlock city-scale energy saving and peak load shaving potential of green roofs by GIS-informed urban building energy modelling. *Applied Energy*, 366, 123315.  
<https://doi.org/https://doi.org/10.1016/j.apenergy.2024.123315>
- Zhu, X., Guo, H., & Huang, J. J. (2024). Urban flood susceptibility mapping using remote sensing, social sensing and an ensemble machine learning model. *Sustainable Cities and Society*, 108, 105508. <https://doi.org/https://doi.org/10.1016/j.scs.2024.105508>