



KLASIFIKASI SEBARAN SPASIAL *HOTSPOTS* DI KALIMANTAN BARAT MENGGUNAKAN METODE *SUPPORT VECTOR MACHINE*

Naomi Nessyana Debataraja¹, Evi Nopita Sari², Joannes Fregis
Philosovio Anugrahnu³, Claudia Bella Hardiana⁴

^{1,2,3}Program Studi Statistika, Universitas Tanjungpura, Pontianak 78115, Indonesia

⁴Program Studi Ilmu Tanah, Universitas Tanjungpura, Pontianak 78115, Indonesia

Jalan Prof. H. Hadari Nawawi, Pontianak

email: naominessyana@math.untan.ac.id

ABSTRACT

Forest fires are a serious environmental issue that often leads to significant ecological and economic damage. In response, efforts have been made to predict and mitigate the impact of forest degradation by improving classification techniques. This study aims to use Support Vector machine (SVM) method to analyze the spatial distribution of forest fires in West Kalimantan. The model uses historical hotspot data as the dependent variable and considers various independent variables, including slope, topography, distances from rivers, settlements and roads, and land cover types. Due to the non-linear nature of the data, the SVM has been enhanced using the Gaussian Radial Basis Function (RBF) kernel. Optimal performance was achieved with cost (c) parameter values of 2, resulting in a classification accuracy of 75.86%. These findings suggest that, when supported by an appropriate kernel function, SVM is a viable and effective approach for mapping and analyzing forest fire-prone areas. The model provides a valuable decision-making tool for forest fire prevention and land management planning in regions with similar environmental characteristics.

Keywords: spatial, kernel, classification, machine learning, kernel

ABSTRAK

Kebakaran hutan merupakan masalah lingkungan yang serius yang sering kali mengakibatkan kerusakan ekologi dan ekonomi yang signifikan. Berbagai upaya telah dilakukan untuk memprediksi dan mengurangi dampak degradasi hutan dengan meningkatkan teknik klasifikasi. Penelitian ini bertujuan untuk menggunakan metode *Support Vector Machine* (SVM) untuk menganalisis sebaran spasial kebakaran hutan di Kalimantan Barat. Model ini menggunakan data hotspots historis sebagai variabel dependen dan mempertimbangkan berbagai variabel independen, termasuk kemiringan, topografi, jarak dari sungai, pemukiman dan jalan, dan jenis tutupan lahan. Karena sifat data yang non-linier, SVM telah ditingkatkan menggunakan kernel *Gaussian Radial Basis Function* (RBF). Kinerja optimal dicapai dengan nilai parameter cost (c) 2, sehingga menghasilkan akurasi klasifikasi sebesar 75,86%. Temuan ini menunjukkan bahwa, jika didukung oleh fungsi kernel yang tepat, SVM merupakan pendekatan yang layak dan efektif untuk memetakan dan menganalisis wilayah rawan kebakaran hutan. Model ini menyediakan alat pengambilan keputusan yang berharga untuk pencegahan kebakaran hutan dan perencanaan pengelolaan lahan di wilayah dengan karakteristik lingkungan yang serupa.

Kata kunci: spasial, kernel, klasifikasi, machine learning, kernel

Received: 21 January 2025, Accepted: 2 July 2025, Published: 11 July 2025

PENDAHULUAN

Hutan menyediakan banyak sumber daya untuk berbagai kehidupan di bumi dan memberikan kontribusi yang tinggi bagi kehidupan manusia. Fenomena alam yang sering terjadi dan berpengaruh besar terhadap seluruh kehidupan di bumi adalah bencana kebakaran hutan. Ada berbagai dampak yang dapat ditimbulkan dari bencana ini, salah satunya adalah berkurangnya sumber oksigen, hilangnya keanekaragaman hayati, perubahan pada kualitas tanah, dan menurunkan perekonomian. Selain fenomena alam, aktivitas manusia juga dapat berperan penting dalam risiko kebakaran hutan. Kepadatan penduduk yang tinggi di suatu tempat akan mengundang lebih banyak aktivitas manusia yang dapat menimbulkan peristiwa kebakaran hutan (Cahyani, *et al.*, 2024).

Provinsi Kalimantan Barat merupakan kawasan yang rawan akan bencana kebakaran lahan dikarenakan sebagian besar wilayah Kalimantan Barat adalah jenis hutan dan lahan gambut yang mudah terbakar. Luas wilayah Kalimantan Barat didominasi oleh jenis hutan sebesar 63,27%. Kondisi alam wilayah Kalimantan Barat merupakan wilayah tropis dengan suhu udara tinggi. Selain itu wilayah Kalimantan Barat juga merupakan wilayah tropis dengan suhu udara tinggi (Aguntar, *et al.*, 2023). Kondisi alam ini dapat mengindikasikan tingginya tingkat kerawanan kebakaran hutan. Berdasarkan kondisi alam Kalimantan Barat perlu adanya usaha untuk mewaspadaai guna mencegah terjadinya bencana kebakaran lahan. Usaha yang dapat dilakukan adalah memperkirakan area terbakar berdasarkan data historis kebakaran lahan dan faktor penyebabnya. Dengan kemajuan metode komputasi, kebakaran lahan dapat diprediksi dengan tingkat akurasi yang baik. Klasifikasi merupakan salah satu teknik pembelajaran yang paling umum digunakan untuk data kategorik.

Pada penelitian ini menggunakan teknik klasifikasi, dengan memperkirakan area kebakaran atau tidak berdasarkan *hotspots*. *Hotspot* sebagai variabel dependen dan dikodekan dengan 1 yang berarti merupakan area kebakaran hutan sedangkan kode 0 untuk area non kebakaran hutan. Variabel independen yang digunakan berjumlah enam variabel, yaitu kemiringan lereng, topografi, jarak titik ke sungai, jarak titik ke pemukiman, jarak titik ke jalan, dan tutupan lahan. Terdapat banyak metode untuk menangani kasus klasifikasi, salah satunya *Support Vector Machine* (SVM) (Islamiyah, *et al.*, 2018). SVM merupakan pembelajaran mesin yang efektif untuk kasus klasifikasi. Karena data yang digunakan bersifat non-linear, maka metode SVM dikolaborasikan dengan memasukkan fungsi kernel. Fungsi kernel yang digunakan yaitu kernel *Gaussian* (RBF). Dalam penelitian ini metode *Support Vector Machine* (SVM) dengan fungsi kernel *Gaussian* (RBF) diterapkan dengan tujuan mengklasifikasikan faktor kebakaran hutan Kalimantan Barat berdasarkan variabel-variabel independen yang telah ditentukan.

TINJAUAN PUSTAKA

Kebakaran hutan merupakan salah satu permasalahan lingkungan yang signifikan, khususnya di wilayah tropis seperti Kalimantan Barat. Identifikasi dan prediksi titik rawan kebakaran menjadi krusial untuk mitigasi bencana. Salah satu pendekatan yang digunakan adalah penggabungan data spasial dengan metode pembelajaran mesin seperti *Support Vector Machine* (SVM), yang terbukti efektif dalam berbagai studi klasifikasi berbasis spasial dalam satu dekade terakhir (Li, *et al.*, 2024). Data spasial seperti *Digital Elevation Model* (DEM), tutupan lahan dan jaringan hidrologi atau infrastruktur sangat membantu dalam menjelaskan faktor-faktor penyebab kebakaran hutan. Menurut (Aguntar, *et al.*, 2023), variabel seperti kemiringan lereng, jarak ke sungai dan tutupan lahan sangat berpengaruh terhadap kerentanan wilayah terhadap kebakaran. Sistem Informasi Geografis (SIG) memungkinkan visualisasi dan analisis spasial secara menyeluruh, serta mendukung pengambilan keputusan berbasis data historis (Gigovic, *et al.*, 2019).

Penggunaan SVM dalam klasifikasi data non-linier menuntut penerapan fungsi kernel, yang mengubah data dari ruang input ke ruang fitur berdimensi lebih tinggi sehingga memungkinkan pemisahan antar kelas (Bui, *et al.*, 2015) (Zhalehdoost & Taleai, 2022). Fungsi kernel *Gaussian Radial Basis Function* (RBF) banyak direkomendasikan untuk data dengan distribusi non-linier karena kemampuannya membentuk *decision boundary* yang fleksibel (Gigovic, *et al.*, 2019) (Pal, 2006). Penelitian oleh (Rihan, *et al.*, 2023) menunjukkan bahwa SVM dengan kernel Gaussian memberikan performa tinggi dalam mendeteksi area rawan kebakaran bila dibandingkan dengan metode klasifikasi konvensional lainnya. Dalam Pembangunan model prediktif, tahapan penting seperti preprocessing data, skoring, pembagian data (*training dan testing*), serta validasi menggunakan *confusion matrix* merupakan langkah-langkah standar dalam *machine learning* (Yuh, *et al.*, 2023). Validasi model berdasarkan akurasi prediksi mampu menunjukkan keandalan sistem klasifikasi yang dibangun, terutama dalam konteks spasial yang kompleks seperti kebakaran hutan (Sunarharum *et al.*, 2018).

METODE PENELITIAN

Sampel yang digunakan pada penelitian ini adalah 144 titik yang diambil secara acak yang terdiri dari 72 *hotspots* dan 72 *non-hotspots*. Teknik pengumpulan data primer dilakukan melalui observasi langsung (Kusnandar, *et al.*, 2019). Teknik sampling yang digunakan adalah sampel acak terstratifikasi. Data primer yang digunakan berjumlah enam variabel independen yaitu kemiringan lereng, topografi, jarak titik ke sungai, jarak titik ke pemukiman, jarak titik ke jalan, dan tutupan lahan. Peta yang digunakan pada observasi variabel independen yaitu peta *Digital Elevation Model* (DEM) Kalimantan Barat, peta tutupan lahan Kalimantan Barat, peta tematik, dan peta administrasi Kalimantan Barat. Selain itu data *hotspot* Kalimantan Barat digunakan sebagai variabel dependen yang diperoleh dari


Moderate Resolution Imaging Spectroradiometer (MODIS). Semua peta yang diperoleh kemudian divisualisasikan menggunakan Sistem Informasi Geografis (SIG) untuk mendapatkan data historis kebakaran hutan di Kalimantan Barat.

Tahapan selanjutnya adalah *preprocessing* data, diikuti proses skoring untuk memberi nilai pada masing-masing parameter sesuai dengan kriteria tertentu. Data yang telah diberi skor dibagi menjadi dua bagian, yaitu data training sebanyak 80% dan data testing sebanyak 20%. Data training digunakan untuk membangun model klasifikasi, sedangkan data testing berfungsi untuk mengevaluasi model tersebut berdasarkan tingkat akurasi (Dasmase, *et al.*, 2022).

Langkah selanjutnya yaitu melakukan estimasi parameter model SVM. Pembelajaran SVM bertujuan untuk menemukan garis linier yang mampu memisahkan antara dua buah kelas (*hyperplane*). Pada dasarnya, SVM terbatas untuk data yang bersifat linier saja, sehingga sebuah pengembangan diperlukan agar SVM dapat diimplementasikan pada data non-linier. Fokus pada penelitian ini adalah menerapkan SVM pada data non-linear. Optimasi parameter pada kasus non-linear ditunjukkan pada Persamaan (1) berikut

$$\hat{\alpha} = \arg \min \frac{1}{2} \alpha_i \alpha_j y_i y_j K(x_i, x_j) - \sum_{i=1}^n \alpha_i \quad (1)$$

dengan batasan: $0 \leq \alpha_i \leq C, i = 1, \dots, n$ dan $\sum_{i=1}^n \alpha_i y_i = 0$. Penyelesaian permasalahan non-linear dilakukan dengan cara SVM yang dimodifikasi dengan memasukkan fungsi kernel (Gigovic, *et al.*, 2019). Fungsi kernel akan membuat data yang pada awalnya secara linier tak dapat terpisah, menjadi dapat dibawa ke dimensi yang lebih tinggi sehingga *hyperplane* dapat dikonstruksi pada dimensi tersebut (Gigovic, *et al.*, 2019).




Gambar 1. Ruang Dimensi Data pada Kernel

Fungsi kernel yang umum digunakan adalah sebagai berikut.

Tabel 1. Jenis-Jenis Kernel

Nama Kernel	Definisi Fungsi
<i>Linier</i>	$K(x, y) = x \cdot y$
<i>Polinomial</i>	$K(x, y) = (x \cdot y + c)^d$
<i>Gaussian</i> (RBF)	$K(x, y) = \exp\left(\frac{-\ x - y\ ^2}{2 \cdot \sigma^2}\right)$

Penentuan fungsi kernel dapat berpengaruh pada hasil prediksi pada klasifikasi SVM. Berdasarkan data yang diperoleh yaitu data dalam bentuk non-linear, maka proses SVM yang digunakan adalah proses non-linear. Bentuk pola pada kernel trick dalam Tabel 1 ditunjukkan pada Gambar 2, 3, dan 4 berikut (Mellit & Kalogirou, 2008).

**Gambar 2.** Pola kernel (a) *linear*, (b) *polynomial* dan (c) *Gaussian RBF*

Menurut (Mellit & Kalogirou, 2008) fungsi kernel yang direkomendasikan untuk penelitian pada data dengan dimensi yang lebih tinggi (non-linear) adalah kernel *Gaussian RBF*, karena memiliki performansi yang sama dengan kernel linear pada parameter tertentu. Persebaran titik pada penelitian ini mengikuti pola kernel *Gaussian RBF*, sehingga kernel yang digunakan adalah fungsi kernel *Gaussian RBF* dengan parameter *cost* (c) dan *gamma* (γ).

Fungsi kernel *Gaussian* (RBF) dengan parameter *cost* (c) dan *gamma* (γ) yang dihasilkan kemudian dilakukan perbandingan dengan mencari parameter yang optimal. Setelah diperoleh parameter yang optimal, kemudian dilakukan pemodelan

dan diuji menggunakan data testing. Validasi model diukur menggunakan akurasi dengan perhitungan *confusion matrix*.


Tabel 2. *Confusion matrix* untuk klasifikasi dua kelas

Kelas Aktual	Kelas Prediksi	
	Kelas (1)	Kelas (0)
Kelas (1)	x_{11}	x_{10}
Kelas (0)	x_{01}	x_{00}

$$\begin{aligned} \text{Akurasi (\%)} &= \frac{\text{Jumlah titik yang diprediksi benar}}{\text{Jumlah prediksi yang dilakukan}} \\ &= \frac{x_{11} + x_{00}}{x_{11} + x_{10} + x_{01} + x_{00}} \times 100\% \end{aligned} \quad (2)$$

HASIL DAN PEMBAHASAN

Pada Penelitian menggunakan data kebakaran hutan di Kalimantan Barat tahun 2020. Sebaran spasial *hotspots* di Kalimantan barat disajikan pada Gambar 3.



Gambar 3. Peta persebaran spasial *hotspots* di Kalimantan Barat tahun 2020

Skoring merupakan tahapan penilaian atau pemberian nilai untuk setiap masing-masing kelas pada setiap parameter. Pemberian nilai tersebut didasarkan adanya efek kelas terhadap kejadian kebakaran. Nilai skor yang semakin tinggi pada masing-masing parameter menunjukkan pengaruh yang semakin besar terhadap tingkat kebakaran hutan.

Tabel 3. *Skoring* variabel kemiringan lereng

Kemiringan lereng	Skor
0 – 8%	5
>8 – 15%	4
>16 – 25%	3
>26 – 45%	2
>45%	1

Kemiringan lereng merupakan satu dari banyak faktor yang mempengaruhi cepat lambatnya penjaran panas. Perilaku *hotspots* saat terjadinya kebakaran hutan menjalar dengan cepat ke arah atas lereng daripada ke arah bawah lereng. Tabel 3 menunjukkan pembagian skor menjadi lima kelas (Sunarharum, *et al.*, 2018).

Tabel 4. *Skoring* variabel topografi

Topografi (m)	Skor
<40	1
>40 - 90	2
>90 - 130	3
>130 - 220	4
>220 - 500	5
>500	6

Pada kondisi tempat yang rendah dapat berpotensi tinggi untuk terjadinya kebakaran hutan. Sebaliknya pada kondisi tempat yang tinggi memiliki potensi yang kecil untuk terjadinya kebakaran hutan (Cahyani, *et al.*, 2024). Tabel 4 merupakan pembagian skor pada topografi yang terbagi menjadi enam kelas.

Tabel 5. *Skoring* variabel jarak titik ke sungai

Jarak titik ke sungai (Km)	Skor
<1	1
1 - 2	2
>3	3

Semakin dekat jarak titik panas ke sungai maka semakin rendah risiko terjadinya kebakaran hutan. Sedangkan semakin jauh jarak titik panas ke sungai maka risiko kebakaran hutan semakin tinggi. Klasifikasi jarak dari titik ke sungai dibagi menjadi 3 bagian (Sunarharum, *et al.*, 2018). Tabel 5 menunjukkan pembagian skor jarak dari titik ke sungai yang terbagi menjadi tiga kelas.

Tabel 6. *Skoring* variabel jarak titik ke pemukiman

Jarak titik ke permukiman (Km)	Skor
<1	1
1 - 2	2
>3	3

Aktivitas manusia di wilayah pemukiman dapat menyebabkan kebakaran hutan. Semakin jauh lokasi permukiman dari titik panas maka kemungkinan hutan untuk terbakar semakin kecil. Sebaliknya semakin dekat lokasi permukiman dari *hotspots* maka kemungkinan hutan untuk terbakar semakin besar (Sunarharum, *et al.*, 2018). Tabel 6 menunjukkan pembagian jarak titik ke permukiman yang terbagi menjadi tiga kelas.

Tabel 7. *Skoring* variabel jarak titik ke jalan

Jarak titik ke jalan (Km)	Skor
<1	1
1 - 2	2
>3	3

Jalan merupakan akses lalu lintas, dimana aktivitas lalu lintas utama menggunakan jalan. Sama halnya dengan permukiman, penduduk melakukan salah satu aktivitas sehari-hari menggunakan jalan. Semakin dekat jarak titik ke jalan memiliki potensi yang besar terhadap terjadinya kebakaran hutan. Sebaliknya semakin jauh jarak titik ke jalan maka memiliki potensi yang kecil terhadap terjadinya kebakaran hutan (Sunarharum, *et al.*, 2018). Tabel 7 menunjukkan pembagian jarak titik ke jalan yang terbagi menjadi tiga kelas.

Tabel 8. *Skoring* variabel tutupan lahan

Tutupan Lahan	Skor
Semak belukar, Pertanian lahan kering	7
Belukar rawa, hutan lahan kering sekunder, hutan tanaman industri, pertanian lahan kering dan semak	6
Hutan rawa sekunder, Perkebunan	5
Hutan lahan kering primer, Hutan rawa primer	4
Hutan mangrove sekunder	3
Hutan mangrove primer	2
Tambak, Tanah terbuka, Bandara, Pelabuhan, Rawa, Tubuh Air, Permukiman/ Transmigrasi, Sawah, Pertambangan	1

Jenis lahan yang memiliki bahan mudah terbakar seperti semak belukar atau pertanian lahan kering merupakan lahan yang berpotensi mengalami kebakaran hutan. Daun dari semak belukar tersebut yang menjadi sumber penyebab api ketika musim kemarau tiba. Oleh sebab itu, tinggi rendahnya potensi kebakaran hutan dapat disebabkan oleh jenis lahan. Tabel 8 menyajikan jenis lahan yang terbagi menjadi tujuh bagian. Semakin tinggi nilai skor yang diberikan maka jenis lahan

merupakan lahan yang sangat peka dan jenis lahan yang mudah terbakar. Sebaliknya semakin kecil skor, maka jenis lahan merupakan lahan yang sulit untuk terbakar (Sunarharum, *et al.*, 2018).

Setelah melakukan *skoring* maka metode SVM diterapkan dengan memasukkan fungsi kernel *Gaussian* (RBF), karena data yang digunakan adalah data non-linear. Analisis fungsi menggunakan kernel *Gaussian* RBF dilakukan untuk mengoptimasi parameter *cost* (c) dan *gamma* (γ). Dalam penentuan parameter terbaik, fungsi kernel RBF dilakukan dengan *trial* dan *error*.

Tabel 9. Nilai akurasi parameter terbaik dengan *trial* dan *error* untuk data *training*

Parameter Data Training		
<i>Cost</i> (C)	<i>Gamma</i> (γ)	<i>Error</i>
1	2	0.2946970
10	2	0.2946970
50	2	0.2946970
100	2	0.2946970

Berdasarkan hasil *trial* dan *error* pada Tabel 7 menunjukkan bahwa nilai *error* terkecil yaitu dengan pasangan *cost* (c) = 1 dan *gamma* (γ) = 2. Selanjutnya dilakukan pemodelan menggunakan parameter terbaik yaitu $c = 1$ dan $\gamma = 2$ pada data *training*, sehingga memperoleh model seperti yang disajikan pada Tabel 9.

Tabel 10. Tabel parameter terbaik model kernel RBF

Parameters	
SVM - Type	<i>C-classification</i>
SVM Kernel	Radial
<i>Cost</i>	1
<i>Gamma</i>	2
<i>Number of Support Vectors</i>	102

Evaluasi model SVM dapat dihitung menggunakan *confusion matrix* sehingga menghasilkan nilai akurasi sebagai berikut.

Tabel 11. Tabel *confusion matrix* data *testing*

Kelas aktual	Kelas prediksi	
	Kelas (1)	Kelas (0)
Kelas (1)	13	5
Kelas (0)	2	9

Setelah diperoleh hasil *confusion matrix*, ketepatan model data *training* dihitung menggunakan nilai akurasi dari data *testing* menggunakan perhitungan sebagai berikut.

$$akurasi (\%) = \frac{x_{11} + x_{00}}{x_{11} + x_{10} + x_{01} + x_{00}} \times 100\%$$

$$akurasi (\%) = \frac{13 + 9}{13 + 9 + 5 + 2} \times 100\%$$

$$akurasi (\%) = 0,7586206897 \times 100\%$$

$$akurasi (\%) = 75,86\%$$

KESIMPULAN

Model SVM yang dibangun dan divalidasi menggunakan data testing menunjukkan performa klasifikasi yang cukup baik, dengan akurasi sebesar 75,86% dan keberhasilan mengklasifikasikan 13 dari 29 sampel secara benar. Berdasarkan hasil tersebut, dapat disimpulkan bahwa metode SVM dengan kernel *Gaussian* (RBF) layak digunakan untuk klasifikasi sebaran spasial kebakaran hutan di Kalimantan Barat, karena mampu memberikan hasil yang cukup akurat dan dapat dijadikan alternatif dalam mendukung analisis spasial pada permasalahan serupa.

UCAPAN TERIMA KASIH

Terimakasih kepada Direktorat Pembelajaran dan Kemahasiswaan yang telah mendanai penelitian ini. Terimakasih kepada Ir. Dadan Kusnandar, M.Sc., Ph.D dan Nurainul Miftahul Huda, M.Si. yang telah mengizinkan penulis menggunakan data dan memberikan masukan terhadap artikel ini.

REFERENSI

- Aguntar, Y., Aghni, P. P., Juliyani, A., Rohman, M. A., Albab, M. A., & Pratiwi, A. D. (2023). Mapping of Forest Fire Vulnerability Using Information Value Model in West Kalimantan Province. *Jurnal Ilmu kehutanan*, 194-205.
- Bui, D. T., Tuan, T. A., Klempe, H., Pradhan, B., & Revhaug, I. (2015). Spatial Prediction Models for Shallow Landslide Hazards: A Comparative Assessment of The Efficacy of Support Vector Machines, Artificial Neural Networks, Kernel Logistic Regression, and Logistic Model Tree. *Landslides*, 1-18.
- Cahyani, C. F., Kusnandar, D., Debataraja, N. N., & Martha, S. (2024). Cluster Mapping of Hotspots Using Kernel Density Estimation in West Kalimantan. *BAREKENG: J. Math & App.*, 2353-2362.
- Dasmasela, R., Tomasouw, B. P., & Leleury, Z. A. (2022). Penerapan Metode Support Vector Machine (SVM) untuk Mendeteksi Penyalahgunaan Narkoba. *PARAMETER: Jurnal Matematika, Statistika dan Terapannya*, 111-122.
- Gigovic, L., Pourghasemi, H., Drobnjak, S., & Bai, S. (2019). Testing a New Ensemble Model Based on SVM and Random Forest in Forest Fire Susceptibility Assessment and Its Mapping in Serbia's Tara National Park. *forests*, 1-21.
- Islamiyah, N., Dengen, E., Maria, & Taruk, M. (2018). Classification of Hotspot in East Kalimantan Forest with VIIRS Sensors using Support Vector Machine. *2018 2nd borneo International Conference on Applied Mathematics and Engineering (BICAME)*. 153-157. Balikpapan: IEEE.

- Kusnandar, D., Debataraja, N. N., Mara, M. N., & Satyahadewi, N. (2019). *Metode Statistika serta Aplikasinya dengan MINITAB, Excel & R*. Pontianak: UNTAN Press.
- Li, Y., Fu, B., Yin, Y., Hu, X., Wang, W., Wang, W., & Long, G. (2024). Review on The Artificial Intelligence-Based Methods in Landslide Detection and Susceptibility Assessment: Current Progress and Future Directions. *Intelligent Geoengineering*, 1-18.
- Mellit, A., & Kalogirou, S. A. (2008). Artificial Intelligence Techniques for Photovoltaic Applications: A review. *Progress in Energy and Combustion Science*, 574-632.
- Pal, M. (2006). Support Vector Machine-Based Feature Selection for Land Cover Classification: A Case Study with DAIS Hyperspectral Data. *International Journal of Remote Sensing*, 2877-2894.
- Rihan, M., Bindajam, A. A., Talukdar, S., Shahfadam, Naikoo, M. W., Mallick, J., & Rahman, A. (2023). Forest Fire Susceptibility mapping with Sensitivity and Uncertainty Analysis Using Machine Learning and Deep Learning Algorithms. *Advances in Space Research*, 426-443.
- Sunarharum, T. W., Jones, D., & Wilson, A. (2018). Urban Climate Risk Governance in Indonesia: The Need for a Co-Production Model. *Earth's Future*, 1155-1171.
- Yuh, Y. G., Tracz, W., Matthews, H. D., & Turner, S. E. (2023). Application of Machine Learning Approaches for Land Cover Monitoring in Northern Cameroon. *Ecological Informatics*.
- Zhalehdoost, A., & Taleai, M. (2022). A Review of the Application of Machine Learning and Geospatial Analysis Methods in Air Pollution Prediction. *Pollution*, 904-933.