

## Klasifikasi Status Erupsi Gunung Berapi Dengan Menggunakan Metode *Autocorrelation* dan *Support Vector Machine*

Fridy Mandita<sup>1)</sup>, Muhammad Arif Fajriyansah<sup>2)</sup>

<sup>1)2)</sup> Prodi Teknik Informatika, Fakultas Teknik, Universitas 17 Agustus 1945  
Jl. Semolowaru No. 45, Surabaya

<sup>1)</sup> [fridymandita@untag-sby.ac.id](mailto:fridymandita@untag-sby.ac.id)

<sup>2)</sup> [muhamadarifar10@gmail.com](mailto:muhamadarifar10@gmail.com)

### Abstrak

Bencana letusan gunung berapi sering terjadi di Indonesia setiap tahunnya, hal ini disebabkan jumlah gunung berapi di Indonesia saat ini masih banyak yang aktif. Pemantauan yang belum ideal dari segi peralatan maupun Sumber Daya Manusia (SDM) menjadi salah satu faktor dari bahaya letusan gunung berapi. Klasifikasi status erupsi gunung berapi merupakan penerapan teknologi yang akan berguna bagi masyarakat sekitar dan pemerintah untuk meminimalisir kerugian baik korban maupun materi. Dengan itu, dilakukan kombinasi metode *Support Vector Machine* untuk pengklasifikasian status erupsi gunung berapi dan metode *Autocorrelation* untuk mendeteksi adanya event gempa pada data sinyal seismik. Metode *z-score* digunakan untuk melakukan normalisasi terhadap data. Penelitian ini juga membandingkan kinerja kernel SVM yaitu *linear*, *polynomial*, dan *RBF* yang dimana kernel *polynomial* dengan parameter *degree* = 2 memiliki performa terbaik dalam kasus klasifikasi sinyal seismik dengan akurasi sebesar 0.9605. Selain itu, *Z-Score* berkontribusi dengan baik dalam meningkatkan kinerja yang signifikan pada model SVM pada kasus klasifikasi sinyal seismik.

**Kata kunci:** *autocorrelation*, gunung berapi, klasifikasi, *support vector machine*

### Abstract

*Volcanic eruption disasters often occur in Indonesia every year, this is because the number of volcanoes in Indonesia is currently still active. Monitoring that is not yet ideal in terms of equipment and Human Resources (HR) is one of the factors in the danger of volcanic eruptions. Classification of volcanic eruption status is the application of technology that will be useful for local communities and the government to minimize losses both victims and material. With that, a combination of the Support Vector Machine method was carried out for classifying the status of volcanic eruptions and the Autocorrelation method for detecting earthquake events in seismic signal data. The z-score method is used to normalize the data. This study also compares the performance of SVM kernels, namely linear, polynomial, and RBF where the polynomial kernel with parameter degree = 2 has the best performance in the case of seismic signal classification with an accuracy of 0.9605. In addition, the Z-Score contributes well in increasing the significant performance of the SVM model in the case of seismic signal classification.*

**Keywords:** *autocorrelation*, classification, *support vector machine*, volcano

### 1. PENDAHULUAN

Di Indonesia, bencana letusan gunung berapi sering terjadi setiap tahunnya karena negara ini memiliki sejumlah besar gunung berapi yang masih aktif [1]. Salah satu alasan terjadinya bencana gunung berapi di Indonesia dikarenakan lokasi geografis yang terletak diantara lempeng Asia dan Australia.

Kepala Pusat Vulkanologi, Meteorologi dan Bencana Geologi (PVMBG) menjelaskan bahwa sampai saat ini hanya 69 gunung yang terpantau dari 127 gunung berapi aktif yang berada di Indonesia. Namun, dari segi peralatan dan SDM pemantauan tersebut jauh dari kata ideal [1]. Data tersebut mengindikasikan bahwa risiko bahaya letusan gunung berapi memiliki dampak yang signifikan bagi masyarakat Indonesia, dikarenakan kurangnya pemantauan yang baik pada gunung di Indonesia. Banyaknya penduduk yang tinggal di kawasan gunung berapi yang aktif juga menjadi faktor resiko bahaya letusan.

Dalam era digital yang sedang berkembang saat ini, pemanfaatan teknologi menjadi sangat penting digunakan dalam mengatasi berbagai permasalahan sehari-hari. Dalam beberapa dekade terakhir, *Artificial Intelligence* (AI) telah menjadi salah satu perkembangan terdepan dalam dunia teknologi [2]. Maka, pada saat ini manusia mulai berlomba – lomba dalam mengembangkan AI.

Salah satu dari kategori AI yaitu *Machine Learning* (ML) yang memungkinkan sebuah komputer dapat berpikir dan belajar sendiri tanpa diprogram secara eksplisit [3]. Banyak sektor yang telah menggunakan teknologi *Machine Learning* (ML) dalam upaya memecahkan berbagai masalah, termasuk dalam bidang bencana alam seperti gunung berapi. Pengklasifikasian status erupsi gunung berapi aktif dengan menggunakan ML memiliki manfaat yang signifikan, karena dapat membantu masyarakat sekitar dan pemerintah untuk mengambil keputusan antisipatif sehingga korban jiwa dan kerugian materi dapat diminimalisir [4].

Proses klasifikasi status erupsi gunung berapi menggunakan sinyal seismik pernah dilakukan di Tianshan orogenic belt dari tahun 2009 sampai 2017. Pada penelitian ini, digunakan metode SVM untuk mengklasifikasikan *tectonic earthquakes* (TEs), *quarry blast* (QBs), *induced earthquakes* (IEs) dari fitur diskriminan dengan mengamati gelombang P dan gelombang S. Fitur diskriminan berasal dari gambar amplitudo spektral (seismograf). Hasil akurasi metode SVM pada penelitian ini adalah 0.9981 untuk TEs, 0.9993 untuk QBs, dan 0.9962 untuk Ies [5].

Penelitian lain juga melakukan klasifikasi sinyal seismik pada gunung Cotopaxi. Penelitian ini menggunakan Multi-class SVM untuk mendeteksi sinyal seismik yaitu *long period* (LP) dan *Volcano-tectonic earthquakes* (VT). Terdapat dua tahap dalam yang dilakukan dalam penelitian ini yaitu tahap deteksi menggunakan algoritma *Decision Tree* dan tahap klasifikasi menggunakan Multi-class SVM. Pada tahap deteksi menghasilkan akurasi sebesar 98% dan akurasi untuk klasifikasi mencapai 90%. Parameter yang paling optimal dalam klasifikasi adalah menggunakan kernel linear [6].

Metode kombinasi *machine learning* dan *z-score normalization* pada kasus klasifikasi penderita diabetes pernah dilakukan. Rentang nilai variabel yang menjadi penentu penyakit diabetes tidak terdistribusi secara seimbang. Hasil penelitian menunjukkan bahwa penggunaan kombinasi algoritma SVM dan metode *Z-Score* menghasilkan kombinasi terbaik yang menunjukkan kinerja optimal [7].

Pada penelitian ini, digunakan metode SVM. Algoritma yang memiliki performa yang sangat bagus digunakan untuk proses klasifikasi sinyal seismik. Berbeda dari beberapa penelitian sebelumnya, dilakukan proses deteksi sinyal seismik terlebih dahulu menggunakan metode *autocorrelation*. Selain itu, diterapkan proses normalisasi data menggunakan *z-score* yang diharapkan mampu meningkatkan kinerja akurasi model SVM.

## 2. TINJAUAN PUSTAKA

### 2.1 *Support Vector Machine* (SVM)

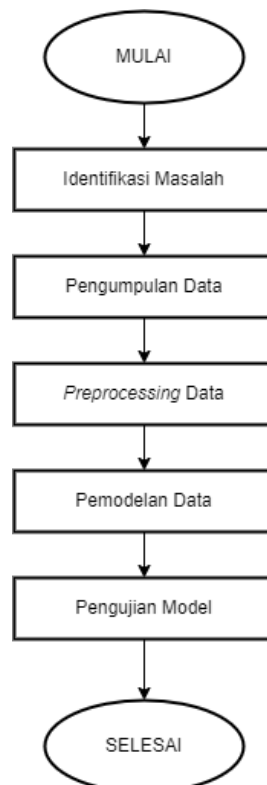
Pada tahun 1992, dalam acara *workshop* tahunan pembelajaran teori komputasi, Vapnik, Guyon, dan Boser memperkenalkan metode *Support Vector Machine* (SVM) [8]. SVM merupakan sebuah algoritma *Machine Learning* yang mengadopsi prinsip meminimalkan resiko struktural untuk mencari garis pemisah (*hyperplane*) pada dua atau lebih kelas dengan optimal [9]. Metode SVM dibagi menjadi dua, yaitu *linear* dan *non-linear*. SVM *linear* berfungsi untuk memisahkan data secara *linear*. Sementara itu, SVM *non-linear* digunakan pada kasus yang tidak dapat terpisah secara *linear* dan memanfaatkan teknik fungsi kernel pada ruang dimensi yang lebih tinggi untuk menemukan *hyperplane* optimal [10].

## 2.2 Autocorrelation

*Autocorrelation* adalah metode deteksi yang didefinisikan dengan menghubungkan sinyal dengan sinyal itu sendiri (dikenal sebagai *auto kovarians* dalam beberapa disiplin ilmu) [11]. Korelasi sendiri adalah sebuah operasi aritmatika yang memiliki kemiripan dengan proses *convolution*. Proses *convolution* sendiri menghitung dua buah sinyal untuk mendapatkan sinyal ketiga (*cross correlation*). Metode *autocorrelation* merujuk pada hasil korelasi antara suatu sinyal dengan dirinya sendiri. *Autocorrelation* digunakan sebagai alat analisis untuk mengamati perubahan sinyal seiring waktu dengan memanfaatkan hubungan probabilitas dan ambang batas yang ditetapkan pada nilai 0,5 [12].

## 3. METODE PENELITIAN

Secara garis besar, pada penelitian ini terdiri dari tiga tahap, yaitu *preprocessing* data, pemodelan data, dan pengujian model. Adapun gambaran tahapan penelitian ini dapat dilihat pada Gambar 1.



Gambar 1 Tahapan penelitian

### 3.1 Pengumpulan Dataset

Data yang digunakan pada penelitian ini merupakan data sinyal seismik gunung berapi xyz. Data yang didapatkan sebanyak 2023 data sinyal seismik yang sudah memiliki label/kategori yaitu AP, DG, *Low Frequency*, *Tremor*, *Multhi-phase*, *Rockfall*, VT-A, dan VT-B. Guna pengujian terhadap model, pada penelitian ini dilakukan pembagian data dengan perbandingan 90:10 untuk *training* dan *testing*. Data *training* adalah data sudah memiliki label. Sedangkan data *testing* adalah data yang belum dikenali oleh model. Adapun contoh dataset pada penelitian ini dapat dilihat pada Tabel 1.

Tabel 1 Contoh dataset

X1	X2	X3	...	Y
3.734	1.437	6.262	...	1
8.820	-1.354	1.196	...	3
-4.266	1.122	-1.818		4
2.205	-9.590	8.223		3
1.296	-1.614	5.618		7

Keterangan:

$X_n$  : Kumpulan *array* yang merupakan fitur data

Y : Kelas untuk klasifikasi, 0(ap), 1(dg), 2(*low frequency*), 3(*multiple phase*), 4(*rockfall*), 5(vt-a), dan 6(vt-b)

### 3.2 Preprocessing Data

Preprocessing data merupakan langkah penting dalam pengoptimalan model SVM untuk meningkatkan akurasi. Data sinyal seismik yang digunakan pada penelitian ini memiliki banyak komponen sinyal dengan frekuensi rendah, sehingga fitur dan event sinyalnya perlu dilakukan analisa terlebih dahulu. Adapun beberapa tahapan yang dilakukan dalam preprocessing data adalah sebagai berikut:

- *Autocorrelation*

Pada tahap ini, data diproses pada tahap deteksi dengan mengkonversikannya menjadi bentuk *autocorrelation* melalui fungsi `np.correlate()`. Kemudian, untuk mendeteksi adanya *event* gempa, nilai amplitudo maksimum dari perhitungan *autocorrelation* lebih besar dibandingkan dengan *threshold* yaitu 0,5. Setelah proses deteksi gempa, data yang memiliki *event* gempa akan diubah menjadi spektrogram dan dilakukan pelabelan pada data.

- Normalisasi Data

Sebelum dataset digunakan untuk pemodelan, dilakukan proses normalisasi data menggunakan metode *z-score*. Metode normalisasi *Zero-Mean* dilakukan dengan menggunakan nilai mean dan standar deviasi. Dalam proses standarisasi dataset, skala distribusi nilai diubah sehingga nilai rata-rata yang terlihat pada dataset adalah 0 dan nilai standar deviasi adalah 1 [13]. Metode *z-score normalization* pada penelitian ini digunakan untuk meringkas rentang nilai pada sinyal yang tidak seimbang. Dapat dilihat pada Tabel 2 merupakan hasil normalisasi *z-score*.

Tabel 2 Contoh hasil normalisasi *z-score*

X1	X2	X3	...	Y
-0.224	-0.190	-0.166	...	1
1.001	-0.299	-0.262	...	3
-0.199	1.122	-0.170	...	4
0.114	-0.179	0.901	...	3
-0.302	0.561	-0.236	...	7

### 3.3 Pemodelan Data

Setelah proses *preprocessing* data selesai dilakukan, tahap selanjutnya adalah membuat model SVM yang akan digunakan untuk melakukan klasifikasi pada data *testing*. Dalam penelitian ini, akan digunakan tiga jenis kernel SVM yang berbeda, yaitu *linear*, RBF (*Radial Basis Function*), dan *polynomial* untuk mencari nilai akurasi terbaik. Selain itu, akan dilakukan pengujian dari beberapa parameter terbaik pada setiap kernel tersebut.

### 3.4 Pengujian Model


Dalam pengujian model, metode yang digunakan adalah *confusion matrix*. *Confusion matrix* adalah *matrix* yang memperlihatkan jumlah data pengujian yang diklasifikasikan dengan benar dan jumlah data pengujian yang diklasifikasikan dengan salah pada suatu model klasifikasi [14].

## 4. PEMBAHASAN

Pada penelitian ini dilakukan pengujian parameter terbaik pada setiap kernel. Kemudian, kernel terbaik akan digunakan pada pengujian model. Selain itu, penelitian ini juga melakukan perbandingan kinerja model pada data yang dinormalisasi menggunakan *z-score* dengan data yang tidak dinormalisasi. Berikut adalah beberapa hasil dari pengujian yang dilakukan pada penelitian ini adalah sebagai berikut.

### 4.1 Autocorrelation

Pada langkah ini, dilakukan analisis *event gempa* pada dataset dengan menggunakan perhitungan *autocorrelation*. Hasil analisis ini akan ditampilkan secara visual melalui spektrogram.



Gambar 2 Hasil *autocorrelation*

Pada Gambar 2, terlihat hasil *plotting* data dan deteksi *event gempa* dari data *time series*. Plot pertama menunjukkan data asli dari *time series*, sementara plot kedua menunjukkan hasil perhitungan metode *autocorrelation* dengan deteksi *event gempa* berdasarkan *threshold* (garis merah). Pada akhir *plotting*, terdapat *event* dari *noise* pada setiap sinyal seismik. Semakin merah warna pada gambar, menandakan tingkat kebisingan yang tinggi dalam sinyal. Selanjutnya, data dengan nilai amplitudo lebih dari 0,5 akan diproses menggunakan model SVM.

### 4.2 Pengujian Parameter Kernel SVM

Dalam pengujian ini, digunakan tiga jenis kernel SVM yang berbeda, yaitu *linear*, RBF, dan *polynomial* untuk mencari nilai akurasi terbaik. Adapun hasil dari pengujian dari kernel SVM adalah sebagai berikut:

#### 4.2.1 Linear SVM

Pada tahap implementasi model dengan menggunakan fungsi linear, dilakukan optimasi parameter *Cost* (C) untuk mencapai hasil yang optimal. Beberapa parameter *cost* yang digunakan untuk optimasi adalah 0.001, 0.01, 0.1, 1, 10, dan 100. Adapun hasil pengujian kernel *linear* adalah sebagai berikut.

Tabel 3 Pengujian parameter kernel *linear*

Parameter	Testing data
	Accuracy
Cost = 0.001	0.8817
Cost = 0.01	0.9014
Cost = 0.1	0.9261
Cost = 1	0.9310
Cost = 10	0.9261
Cost = 100	0.9261

Dapat dilihat pada Tabel 3 terdapat beberapa parameter yang memiliki akurasi tinggi seperti parameter 0.1, 1, 10, dan 100. Parameter 1 memiliki nilai akurasi pada data testing tertinggi dibandingkan parameter yang lain dengan akurasi sebesar 0,931. Dikarenakan fokus pada penelitian ini adalah digunakan akurasi *testing* untuk mengukur kinerja model SVM sehingga parameter C = 1 digunakan dalam pembentukan model pada kernel *linear*.

#### 4.2.2 Polynomial SVM

Fungsi kernel *polynomial* merupakan kernel *non-linear* yang sangat cocok digunakan dalam situasi di mana seluruh dataset pelatihan telah mengalami proses normalisasi. Pada tahap implementasi model dengan menggunakan kernel *polynomial*, dilakukan optimasi pada parameter *Cost* (C) dan *Degree* (d). Beberapa parameter *cost* yang digunakan pada penelitian ini adalah 100, 200, 300, 400, dan 500. Sedangkan untuk *degree* yaitu *degree*=1 dan *degree*=2. Adapun hasil pengujian kernel *polynomial* adalah sebagai berikut.

Tabel 4 Pengujian parameter kernel *polynomial*

Parameter	Accuracy	
	<i>degree</i> =1	<i>degree</i> =2
Cost =100	0.9162	0.9605
Cost =200	0.9261	0.9605
Cost =300	0.9261	0.9605
Cost =400	0.9162	0.9605
Cost =500	0.9162	0.9605

Hasil pada Tabel 4 menunjukkan bahwa pada parameter *degree* (d) = 2 memiliki rata – rata akurasi yang tinggi yaitu sebesar 0,9605 dibandingkan dengan parameter *degree* (d) = 1. Sedangkan untuk pemilihan parameter *cost* dengan melihat parameter d=2, pada hasil parameter *cost* memiliki nilai akurasi yang sama pada 100, 200, 300, 400, dan 500 sehingga dapat dilakukan pemilihan pada salah satu nilai *cost*.

### 4.2.3 RBF SVM

Metode ketiga yang diterapkan dalam analisis ini menggunakan SVM dengan RBF kernel. RBF kernel digunakan pada data yang tidak dapat dipisahkan secara linear. Dalam analisis ini, dilakukan optimasi parameter *Cost* (C) dan *Gamma* ( $\gamma$ ) untuk mencapai hasil yang optimal dalam penggunaan RBF kernel. Beberapa parameter *cost* dan *gamma* yang digunakan pada penelitian ini adalah *Cost*=1, *Cost*=10, *Cost*=50, *Cost* =100, dan *Cost*=500. Sedangkan untuk *gamma* yaitu 1, 2, 3, 4, dan 5. Adapun hasil pengujian kernel RBF adalah sebagai berikut.

Tabel 5 Pengujian parameter kernel RBF

Parameter	Akurasi				
	<i>gamma</i>				
	1	2	3	4	5
<i>Cost</i> =1	0.802	0.817	0.822	0.832	0.827
<i>Cost</i> =10	0.857	0.852	0.857	0.857	0.866
<i>Cost</i> =50	0.866	0.857	0.866	0.866	0.866
<i>Cost</i> =100	0.862	0.857	0.866	0.866	0.866

Hasil pada Tabel 5 menunjukkan bahwa pada parameter  $\gamma = 2$  memiliki akurasi paling rendah daripada parameter *gamma* ( $\gamma$ ) lainnya. Sedangkan pada parameter *cost* terbaik yaitu 10, 50, dan 100 dengan akurasi sebesar 0,866.

### 4.3 Analisis Hasil Akurasi Z-score

Pada bagian ini menyajikan analisis perbandingan performa model dari penggunaan metode normalisasi dan tanpa normalisasi. Berikut adalah hasil perbandingan normalisasi dan tanpa normalisasi kinerja model SVM yang diukur menggunakan akurasi terbaik dari setiap parameter kernel.

Tabel 6 Akurasi model tanpa normalisasi

Kernel	Akurasi
Linear	0.8325
Polynomial	0.5369
RBF	0.6551

Tabel 7 Akurasi model dengan z-score


Kernel	Akurasi
Linear	0.9310
Polynomial	0.9605
RBF	0.8669

Dapat dilihat pada Tabel 6 dan Tabel 7 terdapat perbandingan akurasi yang cukup signifikan pada data yang telah dinormalisasi dan tanpa menggunakan normalisasi. Model yang telah

dilakukan normalisasi mempunyai akurasi jauh lebih baik dibandingkan dengan tanpa normalisasi. Hal ini disebabkan karena terdapat perbedaan rentang nilai antar variabel/fitur pada setiap kelas sehingga model akan sangat kesulitan dalam mempelajari pola-pola pada data dan dapat menghasilkan prediksi yang bias karena hanya fokus terhadap kelas yang memiliki rentang nilai tinggi saja.

#### 4.4 Pengujian Confusion Matrix

Adapun hasil pengujian *confusion matrix* adalah sebagai berikut:



Gambar 3 Hasil *confusion matrix* model terbaik

	precision	recall	f1-score	support
0.0	1.00	1.00	1.00	1
1.0	0.87	1.00	0.93	26
2.0	1.00	0.50	0.67	2
3.0	0.98	0.98	0.98	109
4.0	0.97	0.95	0.96	39
5.0	1.00	1.00	1.00	1
6.0	1.00	0.50	0.67	2
7.0	0.95	0.91	0.93	23
accuracy			0.96	203
macro avg	0.97	0.86	0.89	203
weighted avg	0.96	0.96	0.96	203

Gambar 4 laporan klasifikasi model terbaik

Dapat dilihat pada Gambar 3 dan 4, Digunakan model SVM terbaik kernel *polynomial* dengan parameter *cost*=400 dan *degree*=2 karena memiliki kinerja paling baik jika dibandingkan dengan beberapa kernel lainnya. Nilai akurasi yang didapatkan sebesar 0,96 dan nilai rata-rata keseluruhan *precision* sebesar 0,97, *recall* sebesar 0,86, serta *f1-score* sebesar 0,89. Namun dapat dilihat pada Gambar 4 pada 0, 2, 5, dan 6 memiliki hasil kinerja yang kurang baik. Hal ini dikarenakan jumlah dataset pada beberapa kelas tersebut sangat sedikit dibandingkan kelas lain atau *imbalance*.

## 5. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penggabungan metode SVM dan *autocorrelation* dapat diterapkan dalam konteks bencana, khususnya dalam



mengidentifikasi status erupsi gunung berapi menggunakan data sinyal seismik. Setelah melakukan pengujian terhadap parameter setiap kernel SVM, ditemukan bahwa kernel *polynomial* dengan parameter *degree* = 2 yang memiliki performa terbaik dalam kasus klasifikasi sinyal seismik dengan akurasi sebesar 0.9605. Selanjutnya, penggunaan *Z-Score* memiliki kontribusi positif dalam meningkatkan akurasi, seperti yang terlihat dalam perbandingan hasil akurasi antara data yang menggunakan *Z-Score* dan data yang tidak menggunakan normalisasi *Z-Score*.

Namun, dalam penelitian ini terdapat kekurangan dalam mengenali kelas yang memiliki jumlah data training yang sangat sedikit. Untuk mengatasi permasalahan ini, beberapa metode *imbalance* data dapat dicoba, antara lain *undersampling*, *oversampling*, SMOTE, dan metode lainnya.

#### DAFTAR PUSTAKA

- [1] F. Tempola, M. Muhammad, and A. Khairan, "Perbandingan Klasifikasi Antara KNN dan Naive Bayes pada Penentuan Status Gunung Berapi dengan K-Fold Cross Validation," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 5, p. 577, 2018, doi: 10.25126/jtiik.201855983.
- [2] K. R. Ririh *et al.*, "STUDI KOMPARASI DAN ANALISIS SWOT PADA IMPLEMENTASI KECERDASAN BUATAN ( ARTIFICIAL INTELLIGENCE ) DI INDONESIA," vol. 15, no. 2, pp. 122–133, 2020.
- [3] X. Yuan and C. Nayoze-coynel, "Machine Learning from Theory to Algorithms : An Overview Machine Learning from Theory to Algorithms : An Overview," 2018, doi: 10.1088/1742-6596/1142/1/012012.
- [4] F. C. Anggian, N. Hidayat, and M. T. Furqon, "Implementasi Metode Modified K-Nearest Neighbor untuk Klasifikasi Status Gunung Berapi," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 12, pp. 11027–11033, 2019.
- [5] L. Tang, M. Zhang, and L. Wen, "Support Vector Machine Classification of Seismic Events in the Tianshan Orogenic Belt," *J. Geophys. Res. Solid Earth*, vol. 125, no. 1, 2020, doi: 10.1029/2019JB018132.
- [6] R. Lara-Cueva, D. S. Benitez, V. Paillacho, M. Villalva, and J. L. Rojo-Alvarez, "On the use of multi-class support vector machines for classification of seismic signals at Cotopaxi volcano," *2017 IEEE Int. Autumn Meet. Power, Electron. Comput. ROPEC 2017*, vol. 2018-Janua, no. Ropec, pp. 1–6, 2017, doi: 10.1109/ROPEC.2017.8261613.
- [7] I. M. Karo Karo and Hendriyana, "Klasifikasi Penderita Diabetes Menggunakan Algoritma Machine Learning Dan Z-Score," *J. Teknol. Terpadu*, vol. 8, no. 2, pp. 94–99, 2022.
- [8] A. Handayanto, K. Latifa, N. D. Saputro, and R. R. Waliansyah, "Analisis dan Penerapan Algoritma Support Vector Machine (SVM) dalam Data Mining untuk Menunjang Strategi Promosi," *JUITA J. Inform.*, vol. 7, no. 2, p. 71, 2019, doi: 10.30595/juita.v7i2.4378.
- [9] F. Rahutomo, P. Y. Saputra, and M. A. Fidyawan, "Implementasi Twitter Sentiment Analysis Untuk Review Film MenggunaRahutomo, F., Saputra, P. Y. and Fidyawan, M. A. (2018) 'Implementasi Twitter Sentiment Analysis Untuk Review Film Menggunakan Algoritma Support Vector Machine', Jurnal Informatika Polinema," *J. Inform. Polinema*, vol. 4, no. 2, p. 93, 2018.
- [10] A. Rahman Isnain, A. Indra Sakti, D. Alita, and N. Satya Marga, "Sentimen Analisis Publik Terhadap Kebijakan Lockdown Pemerintah Jakarta Menggunakan Algoritma Svm," *Jdmsi*, vol. 2, no. 1, pp. 31–37, 2021, [Online]. Available: <https://t.co/NfhmfMjtXw>
- [11] J. Audretsch, "Earthquake Detection using Deep Learning Based Approaches," 2020. [Online]. Available: <https://repository.kaust.edu.sa/handle/10754/662251>
- [12] R. S. Perdana, C. Fatichah, and D. Purwitasari, "Pemilihan Kata Kunci Untuk Deteksi Kejadian Trivial Pada Dokumen Twitter Menggunakan Autocorrelation Wavelet

- Coefficients,” *JUTI J. Ilm. Teknol. Inf.*, vol. 13, no. 2, p. 152, 2015, doi: 10.12962/j24068535.v13i2.a484.
- [13] A. Ambarwari, Q. J. Adrian, and Y. Herdiyeni, “Analisis Pengaruh Data Scaling Terhadap Performa Algoritme Machine Learning untuk Identifikasi Tanaman,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 1, no. 3, pp. 117–122, 2017.
- [14] D. Normawati and S. A. Prayogi, “Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter,” *J-SAKTI (Jurnal Sains Komput. dan Inform.)*, vol. 5, no. 2, pp. 697–711, 2021.

#### **Biodata Penulis**

**Fridy Mandita**, saat ini bekerja sebagai dosen pada program studi Teknik Informatika Universitas 17 Agustus 1945 Surabaya. Menyelesaikan Sarjana pada Universitas Gadjah Mada dan Master di KMUTNB/RWTH Aachen. Saat ini sedang menempuh Pendidikan Doktoral di Universitas Gadjah Mada. Bidang peminatan adalah AI, Machine Learning, Sign Language, dan IoT. Disamping menjadi dosen juga mengisi pelatihan IT di berbagai institusi dan terlibat dalam beberapa projek sebagai SA ataupun PM.

**Muhammad Arif Fajriyansah**, Lahir di Sidoarjo – Jawa Timur, pada bulan Agustus 2001. Merupakan mahasiswa di Prodi S1 Informatika Fakultas Teknik Universitas 17 Agustus 1945 di kota Surabaya.