

Klasifikasi Risiko Kekerasan Narapidana Berdasarkan Sinyal EEG dengan PCA dan K-Means

Jerry ¹, Luvi Anggelia Pane², Silvia Erika Zega³, Albert Tantowi⁴, Yonata Laia⁵

^{1,2,3,4,5} Sistem Informasi, Universitas Prima Indonesia

Email: ¹ jerryyykhoo17@gmail.com, ²luvipane@gmail.com, ³silviaerikazega13@gmail.com, ⁴alberttantowioke@gmail.com,

Email Penulis Korespondensi: yonata@unprimdn.ac..id

Abstrak

Penelitian ini menggunakan EEG untuk melihat risiko kekerasan narapidana. Kekerasan di lapas sering terjadi, hal ini membahayakan narapidana dan petugas. Data EEG diambil dari 21 narapidana. Sinyal otak ini kemudian dibersihkan dan dinormalisasi. Setelah itu, data diperkecil menggunakan PCA. Terakhir, K-Means clustering dipakai untuk mengelompokkan data. Hasil penelitian menunjukkan 6 kelompok risiko kekerasan. Nilai silhouette score mencapai 0,9338 pada k=6. Ini artinya pengelompokan sangat baik. Metode ini bisa membedakan pola otak yang berhubungan dengan sifat agresif. PCA dan K-Means terbukti efektif mengelompokkan aktivitas otak. Hasil ini bisa dikembangkan menjadi sistem deteksi dini. Dengan begitu, kekerasan di lapas dapat dicegah lebih awal.

Kata Kunci: EEG, Narapidana, Risiko Kekerasan, K-Means Clustering, Principal Component Analysis (PCA)

Abstract

This study utilized EEG to assess the risk of violence among inmates. Violence in correctional facilities poses significant threats to both inmates and staff. EEG data were collected from 21 inmates, then cleaned and normalized. Subsequently, Principal Component Analysis (PCA) was applied to reduce data dimensionality. Finally, K-Means clustering was employed to categorize the data. The analysis revealed six distinct risk groups, with a silhouette score of 0.9338 at k=6, indicating excellent clustering quality. This suggests that the method effectively distinguishes brain activity patterns associated with aggressive traits. The combination of PCA and K-Means proved effective in grouping brain activity, offering potential for early detection systems to prevent violence in correctional facilities.

Keywords: Electroencephalography (EEG), Inmate, Violence Risk, K-Means Clustering, Principal Component Analysis (PCA)

1. PENDAHULUAN

Kekerasan di lembaga pemasyarakatan menjadi masalah yang tidak bisa diabaikan. Pemerintah, lembaga keamanan, dan masyarakat terus mencari solusi untuk mengatasi hal ini [1]. Data menunjukkan bahwa tingkat kekerasan di dalam tahanan cukup tinggi dan membahayakan semua pihak [2]. Tidak hanya narapidana yang menjadi korban, petugas juga sering mengalami ancaman keselamatan. Faktor psikologis dan neurologis berperan besar dalam memicu perilaku agresif narapidana [3][4][5]. Beberapa peneliti menemukan bahwa kondisi mental tertentu dapat meningkatkan kecenderungan kekerasan. Meski demikian, identifikasi risiko kekerasan masih menjadi tantangan besar [6]. Metode yang ada saat ini belum memberikan hasil yang memuaskan. Observasi perilaku dan analisis catatan kriminal adalah pendekatan yang umum digunakan. Sayangnya, kedua metode ini memiliki kelemahan mendasar dalam hal objektivitas. Penilaian yang subjektif sering menghasilkan kesimpulan yang bias atau tidak akurat. Akibatnya, upaya pencegahan kekerasan menjadi kurang efektif dan tepat sasaran.

Electroencephalography (EEG) menawarkan perspektif baru dalam mengatasi masalah ini. Teknologi ini merekam aktivitas listrik otak melalui elektroda yang ditempatkan di kulit kepala. Bidang medis telah menggunakan EEG untuk mendiagnosis epilepsi dan berbagai gangguan neurologis lainnya. Keunggulan EEG terletak pada sifatnya yang non-invasif dan relatif aman untuk digunakan. Penelitian terbaru menunjukkan bahwa sinyal EEG dapat mengungkap kondisi emosional seseorang [7]. Tingkat stres dan kecenderungan agresif dapat terdeteksi melalui pola aktivitas otak tertentu. Namun, kompleksitas data EEG menjadi hambatan utama dalam implementasinya. Data yang dihasilkan memiliki dimensi tinggi dan memerlukan teknik analisis khusus.

Principal Component Analysis (PCA) dapat membantu mengatasi masalah dimensionalitas data EEG. Teknik ini mampu mengurangi kompleksitas data sambil mempertahankan informasi yang penting. Sementara itu, K-Means Clustering memungkinkan pengelompokan narapidana berdasarkan pola aktivitas otak mereka. Kombinasi kedua metode ini berpotensi menghasilkan sistem klasifikasi risiko yang lebih objektif dan akurat.

2. METODOLOGI PENELITIAN

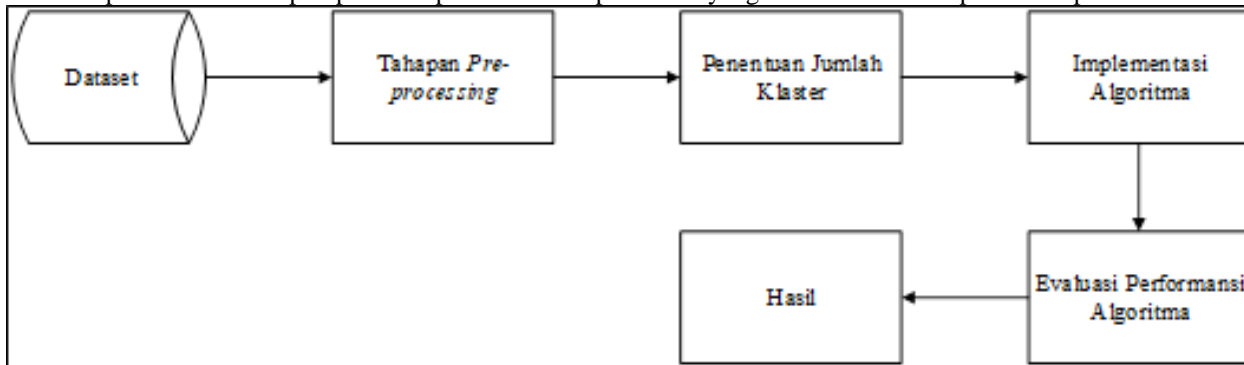
2.1 Jenis Penelitian

Pada penelitian ini, peneliti menggunakan jenis penelitian secara kuantitatif yaitu penelitian yang melibatkan pengumpulan data numerik dan analisis statistik untuk memahami fenomena atau menjawab pertanyaan penelitian. Metode ini sering digunakan untuk mengukur hubungan antara variabel-variabel dan mengidentifikasi pola atau tren dalam data [19]. Dalam hal ini, penelitian yang dilakukan berfokus pada analisis performa algoritma *K-Means Clustering*

dan *Principal Component Analysis* dalam mengidentifikasi resiko tingkat kekerasan pada narapidana di tahanan melalui sinyal EEG.

2.2 Prosedur Penelitian

Dalam penelitian ini adapun prosedur penelitian dari penelitian yang akan dilakukan dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

a. Dataset

Data EEG diperoleh dari 21 subjek yang mengikuti eksperimen dengan mata tertutup dan menggunakan peralatan khusus untuk merekam aktivitas otak. Sinyal EEG awalnya mengandung *noise* tinggi, sehingga dilakukan penyaringan menggunakan *Band Pass Filter* (BPF) dengan rentang frekuensi 0,5 hingga 50 Hz untuk menghilangkan derau yang tidak diinginkan. Setelah proses penyaringan, hanya gelombang otak relevan seperti delta, theta, alfa, dan beta yang dipertahankan. Selain itu, elektroda Fp1 dan Fp2 dihapus, menyisakan 18 titik data untuk analisis lebih lanjut. Data yang sudah difilter memungkinkan peneliti untuk fokus pada aktivitas otak yang diinginkan tanpa gangguan eksternal, seperti kebisingan atau sinyal listrik yang tidak relevan. Berikut ini, Tabel 2.3 menunjukkan contoh dataset penelitian ini.

b. Tahapan *pre-processing*

Tahapan pertama dalam analisis ini adalah *pre-processing* data EEG yang diperoleh. Data yang tidak lengkap atau memiliki nilai yang hilang (*missing values*) diisi dengan menggunakan imputasi nilai rata-rata (*mean imputation*). Kemudian, fitur numerik dari dataset dipilih dan dilakukan normalisasi dengan menggunakan metode *StandardScaler* untuk mengubah nilai-nilai fitur ke dalam skala yang setara, sehingga mempermudah proses analisis selanjutnya [20].

c. Penentuan Jumlah Kluster

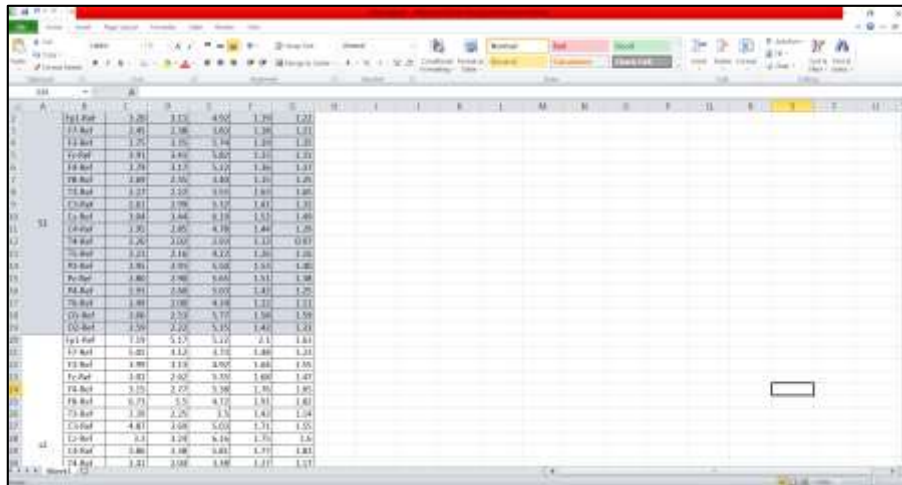
Proses penentuan cluster terbaik dilakukan dengan menggunakan metode Elbow. Metode Elbow adalah salah satu teknik yang digunakan untuk menentukan jumlah kluster (*k*) yang optimal dalam algoritma K-Means clustering. Tujuan dari metode ini adalah untuk menemukan titik di mana penurunan SSE (Sum of Squared Errors) mulai melambat secara signifikan, yang menunjukkan jumlah kluster yang optimal. SSE adalah jumlah dari kuadrat jarak antara titik data dengan pusat kluster (centroid) yang terdekat. Penentuan jumlah kluster divisualisasikan dalam bentuk grafik Elbow [21].

3. HASIL DAN PEMBAHASAN

Hasil pelnguljian yang didapatkan pada pelnellitian ini untuk menganalisis dan mengetahui seberapa besar nilai performa algoritma K-Means Clustering dan *Principal Component Analysis* dalam mengidentifikasi resiko tingkat kekerasan pada narapidana di tahanan melalui sinyal EEG.

3.1 Menyiapkan Dataset

Data EEG diperoleh dari 21 subjek yang mengikuti eksperimen dengan mata tertutup dan menggunakan peralatan khusus untuk merekam aktivitas otak. Sinyal EEG awalnya mengandung *noise* tinggi, sehingga dilakukan penyaringan menggunakan *Band Pass Filter* (BPF) dengan rentang frekuensi 0,5 hingga 50 Hz untuk menghilangkan derau yang tidak diinginkan. Setelah proses penyaringan, hanya gelombang otak relevan seperti delta, theta, alfa, dan beta yang dipertahankan. Selain itu, elektroda Fp1 dan Fp2 dihapus, menyisakan 18 titik data untuk analisis lebih lanjut. Berikut ini, Gambar 3.1 menunjukkan file Excel dataset penelitian ini.

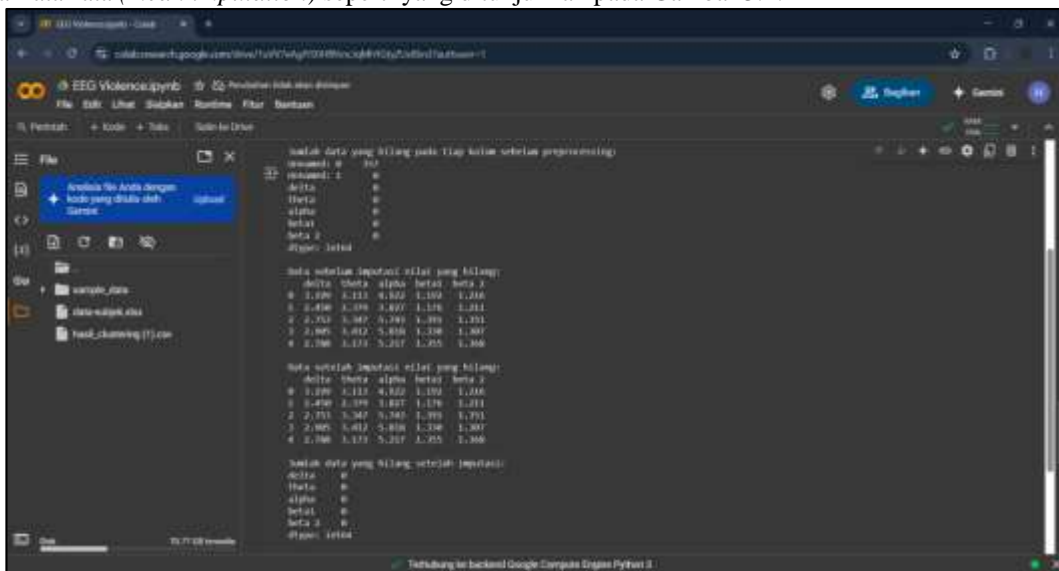


Gambar 2. Dataset Penelitian

Terdapat 18 elektroda setelah proses penyaringan yaitu Fp1-Ref, F7-Ref, F3-Ref, Fz-Ref, F4-Ref, F8-Ref, T3-Ref, C3-Ref, Cz-Ref, C4-Ref, T4-Ref, T5-Ref, P3-Ref, Pz-Ref, P4-Ref, T6-Ref, O1-Ref, dan O2-Ref.

3.2 Hasil Preprocessing Data

Tahapan *preprocessing* data pada penelitian ini dilakukan dengan memanfaatkan *Google Colab* berbasis pemrograman Python. Sebelum dilanjutkan ke tahapan berikutnya, dilakukan tahap *preprocessing* yang terdiri dari tahapan pertama yaitu data yang tidak lengkap atau memiliki nilai yang hilang (*missing values*) diisi dengan menggunakan imputasi nilai rata-rata (*mean imputation*) seperti yang ditunjukkan pada Gambar 3.2.



```

#data yang hilang pada tiap kolom sebelum preprocessing
#sumami: 0
#mu: 0
#sigma: 0
#beta: 0
#alpha: 0
#beta1: 0
#beta 2: 0
#gamma: beta

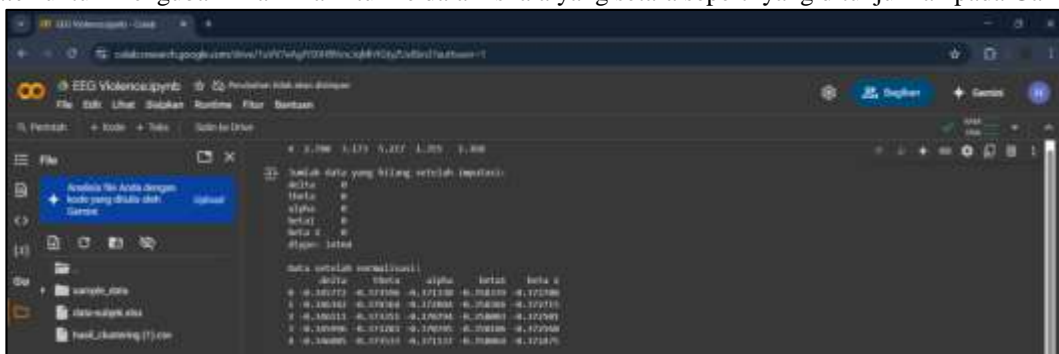
#data setelah imputasi nilai yang hilang:
#delta theta alpha beta1 beta 2
# 1.000 1.113 0.002 1.100 1.100
# 1.400 1.000 1.002 1.100 1.111
# 2.703 1.307 1.003 1.100 1.101
# 3.200 1.012 1.010 1.100 1.007
# 2.000 1.113 1.117 1.105 1.100

#data setelah imputasi nilai yang hilang:
#delta theta alpha beta1 beta 2
# 1.000 1.113 0.002 1.100 1.100
# 1.400 1.000 1.002 1.100 1.111
# 2.703 1.307 1.003 1.100 1.101
# 3.200 1.012 1.010 1.100 1.007
# 2.000 1.113 1.117 1.105 1.100

#data yang hilang setelah imputasi:
#delta: 0
#theta: 0
#alpha: 0
#beta1: 0
#beta 2: 0
#gamma: beta
    
```

Gambar 3. Hasil *Preprocessing* Data Tahapan Pertama

Kemudian, fitur numerik dari dataset dipilih dan dilakukan normalisasi dengan menggunakan metode *StandardScaler* untuk mengubah nilai-nilai fitur ke dalam skala yang setara seperti yang ditunjukkan pada Gambar 3.2.



```

#data setelah normalisasi:
#delta theta alpha beta1 beta 2
# -0.101772 -0.177106 -0.171200 -0.101510 -0.177106
# -0.101011 -0.177104 -0.171200 -0.101010 -0.177104
# -0.100111 -0.171011 -0.170700 -0.100110 -0.172000
# -0.100000 -0.171000 -0.170000 -0.100000 -0.172000
# -0.100000 -0.171011 -0.171101 -0.100000 -0.171101
    
```

Gambar 4. Hasil *Preprocessing* Data Tahapan Kedua

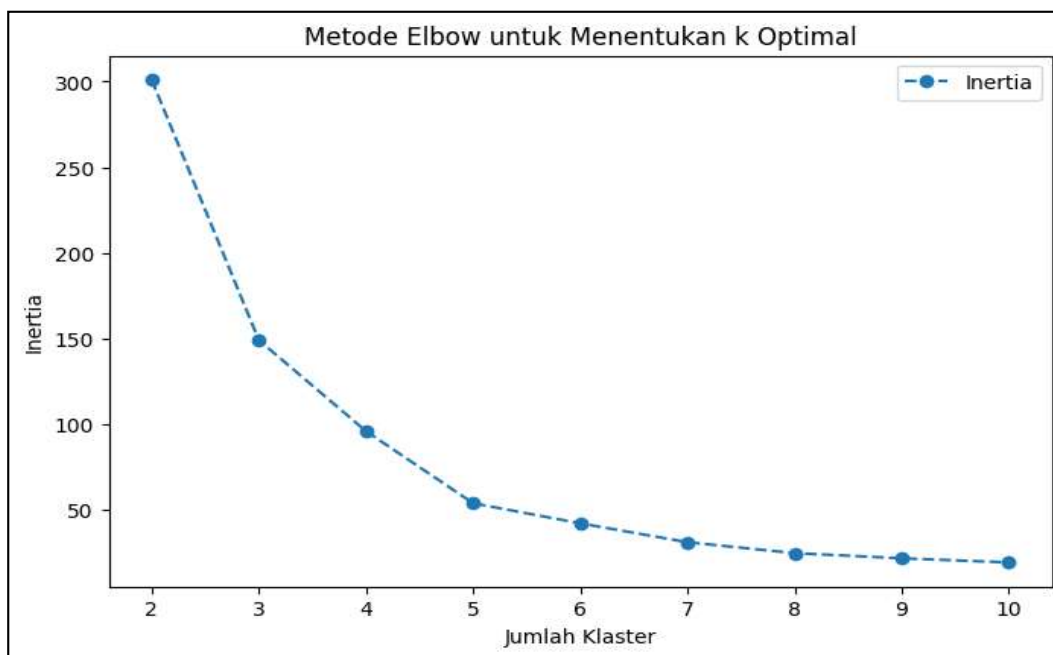
3.3 Hasil Penentuan Jumlah Kluster

Proses penentuan cluster terbaik dilakukan dengan menggunakan metode Elbow. Metode Elbow adalah salah satu teknik yang digunakan untuk menentukan jumlah kluster (k) yang optimal dalam algoritma K-Means clustering. Tujuan dari metode ini adalah untuk menemukan titik di mana penurunan SSE (Sum of Squared Errors) mulai melambat secara signifikan, yang menunjukkan jumlah kluster yang optimal. Berikut ini, Tabel 1. menunjukkan hasil perhitungan SSE.

Tabel 1. Hasil Penentuan Jumlah Kluster

Jumlah Kluster (k)	SSE (Inertia)
2	301.0232
3	148.9702
4	95.77522
5	53.66587
6	41.93132
7	30.89054
8	24.51397
9	21.5145
10	19.10442

Berdasarkan hasil perhitungan SSE pada Tabel 3.1 untuk berbagai jumlah kluster (k), terlihat bahwa nilai SSE terus menurun seiring bertambahnya jumlah kluster. Penurunan terbesar terjadi dari k = 2 ke k = 3 dan seterusnya, namun setelah k = 6, laju penurunan SSE mulai melambat. Hal ini menunjukkan bahwa setelah kluster ke-6, penambahan jumlah kluster tidak memberikan pengurangan SSE yang signifikan, sehingga tidak memberikan manfaat yang sepadan dengan peningkatan kompleksitas model. Pemilihan k = 6 didasarkan pada metode *Elbow*, di mana titik siku terlihat pada k = 6 seperti yang ditunjukkan pada Gambar 3.4, menunjukkan keseimbangan antara jumlah kluster yang optimal dan penurunan SSE yang masih cukup signifikan sebelum melambat. Oleh karena itu, kluster 6 dipilih sebagai jumlah kluster yang optimal untuk segmentasi data ini.

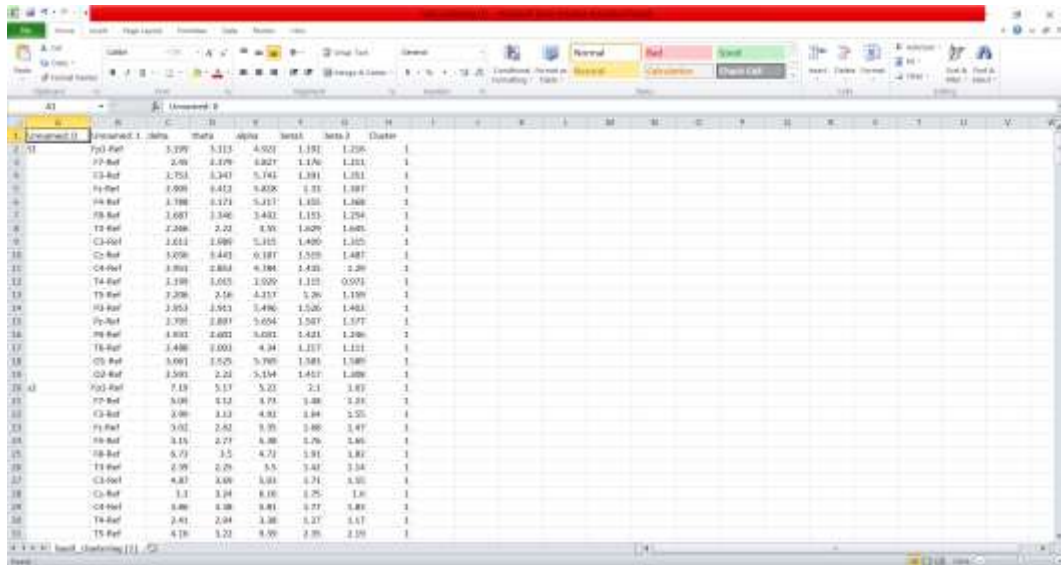


Gambar 5. Hasil Penentuan Jumlah Kluster Berdasarkan Metode *Elbow*

3.4 Implementasi Algoritma

Setelah menentukan jumlah kluster yang optimal, algoritma K-Means diterapkan pada data yang sudah diproses dan dinormalisasi. K-Means mengelompokkan data menjadi kluster-kluster berdasarkan kedekatannya dengan pusat kluster

yang dihitung. Terdapat 6 kluster identifikasi resiko tingkat kekerasan narapidana. Berikut ini, Gambar 5. menunjukkan hasil klasifikasi identifikasi resiko tingkat kekerasan pada narapidana berdasarkan data EEG.



Gambar 6. Implementasi Algoritma *K-Means* Menghasilkan Klasterisasi

Berdasarkan hasil implementasi algoritma didapatkan hasil klasterisasi identifikasi resiko tingkat kekerasan pada narapidana di tahanan yang diuraikan pada Tabel 2. berikut.

Tabel 1. Hasil Klasterifikasi Identifikasi Resiko Tingkat Kekerasan Narapidana

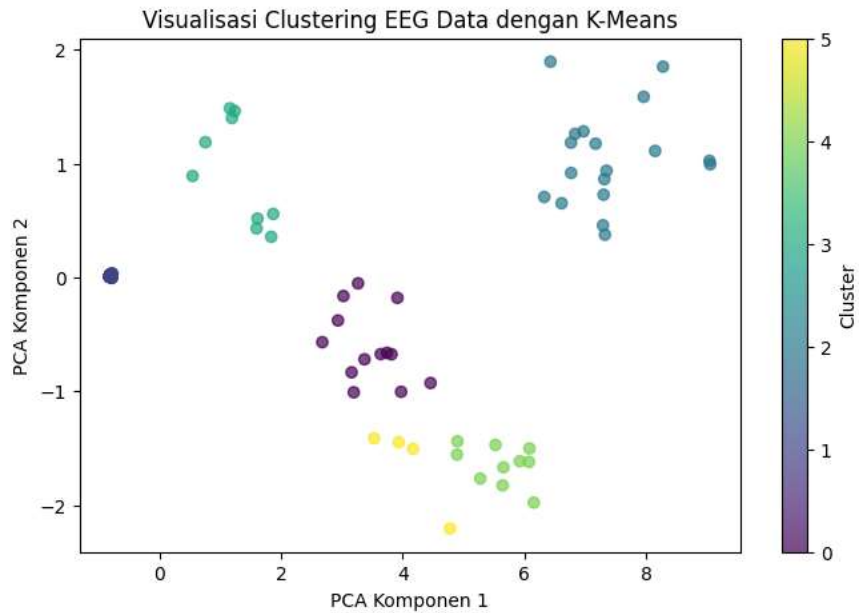
Narapidana	Identifikasi Resiko Tingkat Kekerasan
S1	1
S2	1
S3	1
S4	1
S5	1
S6	2
S7	4
S8	0
S9	1
S10	1
S11	1
S12	1
S13	1
S14	1
S15	1

3.5 Hasil Evaluasi Performansi Algoritma

Untuk mengevaluasi performansi algoritma K-Means, dapat menggunakan dua pendekatan utama yaitu:

- a. Visualisasi *Principal Component Analysis* (PCA).

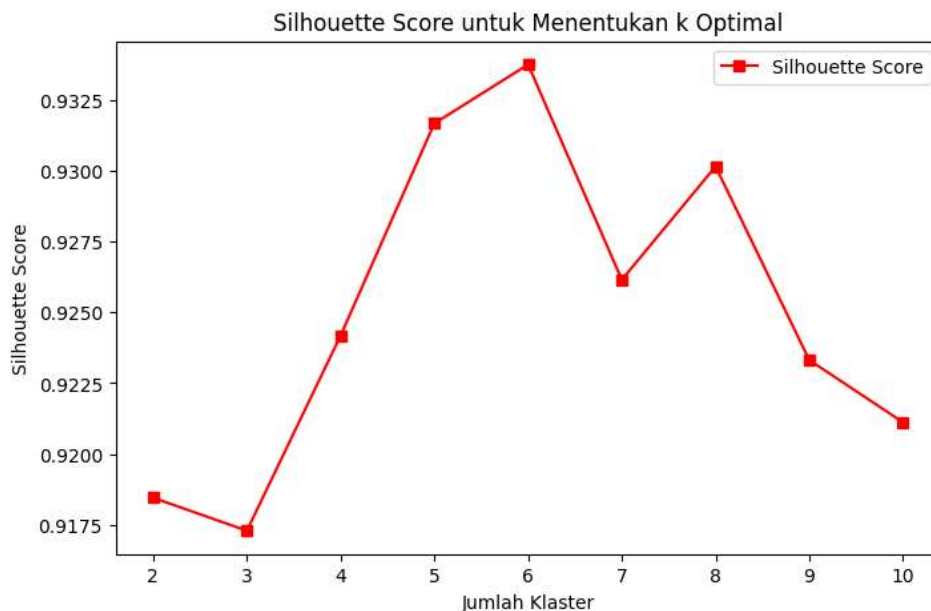
PCA (Principal Component Analysis) digunakan untuk mereduksi dimensi data menjadi 2 komponen utama yang dapat divisualisasikan dengan mudah. Visualisasi ini akan memberikan gambaran mengenai pemisahan kluster yang dihasilkan oleh K-Means. Setiap titik dalam grafik akan mewakili data yang dipetakan ke dalam dua komponen PCA, dengan warna yang menunjukkan kluster tempat titik tersebut tergolong. Berikut ini Gambar 3.6 menunjukkan visualisasi PCA dari setiap kluster resiko tingkat kekerasan narapidana.



Gambar 7. Hasil Evaluasi Visualisasi *Clustering* EEG Data Dengan *K-Means*

b. Silhouette Score.

Silhouette Score adalah metrik yang digunakan untuk mengevaluasi seberapa baik data dikelompokkan dalam kluster. Berikut ini Gambar 8. menunjukkan implementasi Silhouette Score dalam mendapatkan nilai k yang optimal.



Gambar 8. Hasil Pengujian *Silhouette Score*

Berdasarkan grafik Silhouette Score yang ditampilkan pada Gambar 3.7, nilai *Silhouette Score* tertinggi dicapai pada k = 6 dan mendapatkan score 0.9338 yang artinya bahwa pemisahan kluster pada k = 6 adalah yang paling optimal dibandingkan dengan jumlah kluster lainnya. Nilai 0.9338 mendekati 1, yang menunjukkan bahwa objek dalam masing-masing kluster memiliki kesamaan yang tinggi dan jelas terpisah dari kluster lainnya. Hal ini mengindikasikan bahwa pembagian kelompok risiko tingkat kekerasan pada narapidana berdasarkan data EEG dengan algoritma *K-Means Clustering* menjadi lebih terstruktur dan dapat diinterpretasikan dengan baik.

4. KESIMPULAN

Penelitian ini membuktikan bahwa kombinasi PCA dan K-Means efektif untuk mengklasifikasikan risiko kekerasan narapidana berdasarkan sinyal EEG. Proses pre-processing dan reduksi dimensi berhasil menyederhanakan data tanpa menghilangkan informasi penting. Hasil klasterisasi menunjukkan enam kelompok risiko dengan Silhouette Score tertinggi 0,9338, menandakan pemisahan klaster yang optimal. Metode ini dapat menjadi alat bantu objektif dalam mendeteksi dan mengelola potensi perilaku agresif di lingkungan masyarakat.

UCAPAN TERIMAKASIH

Pujin dan syukur kepada Tuhan karena sampai saat ini saya boleh menyelesaikan penelitian saya oleh karena pertolongannya. Terimakasih Kepada dosen-dosen yang telah memberikan kepada saya arahan selama ini. Terlebih kepada dosen pembimbing saya Yoanata laia, M.Kom Juga Kepada orang Tua kami yang selalu mendukung sampai saat ini.

DAFTAR PUSTAKA

- [1] M. F. Lathif and P. Wibowo, "Strategi Penerapan Sistem Keamanan Pada Desain Lembaga Masyarakat Kelas IIB Ngawi," *Innov. J. Soc. Sci. Res.*, vol. 2, no. 1, pp. 197–199, 2022, doi: 10.31004/innovative.v2i1.2955.
- [2] A. F. Mubarakah and N. U. Larasati, "Konflik Antar Narapidana di Lembaga Masyarakat Kelas I Cipinang dalam Perspektif Subkultur Penjara," *Deviance J. Kriminologi*, vol. 7, no. 2, p. 157, 2023, doi: 10.36080/djk.2708.
- [3] B. T. T and R. Y. . Kusumiati, "Hubungan Kontrol Diri Dengan Perilaku Agresif Pada Penjaga Tahanan Di Lapas Kelas Ii a Ambarawa," *Psikol. Konseling*, vol. 18, no. 1, p. 873, 2021, doi: 10.24114/konseling.v18i1.27821.
- [4] M. Coffman, "The Neurological Imprint of Incarceration and Its Effect on Recidivism," *Notre Dame J. Law. Ethics Public Policy*, vol. 37, pp. 251–277, 2023.
- [5] R. H. J. Hornsveld and F. W. Kraaimaat, "Psychological factors predicting violent prison inmates' anger and aggression," *J. Forensic Psychol. Res. Pract.*, vol. 23, no. 5, pp. 472–488, 2023, doi: 10.1080/24732850.2022.2048768.
- [6] M. D. P. Dila, D. R. Monica, E. Dewi, E. Raharjo, and F. B. Tamza, "Penerapan Restoratif Justice Sebagai Upaya Mengurangi Overcapacity Lapas," *J. Ilmu Hukum, Hum. dan Polit.*, vol. 4, no. 5, pp. 1850–1862, 2024.
- [7] Z. Khakim and S. Kusrohmaniah, "Dasar - Dasar Electroencephalography (EEG) bagi Riset Psikologi," *Bul. Psikol.*, vol. 29, no. 1, pp. 92–115, 2021, doi: 10.22146/buletinpsikologi.52328.
- [8] R. S. Ginting, H. Hamdani, A. Septiariani, and F. Alameka, "The Clustering Tindak Kekerasan Dalam Rumah Tangga Di Kota Samarinda Menggunakan Algoritma K-Means," *Metik J.*, vol. 6, no. 2, pp. 172–177, 2022, doi: 10.47002/metik.v6i2.378.
- [9] A. Utari, D. P. Rini, W. K. Sari, and T. Saputra, "Klasifikasi Sinyal EEG Untuk Mengenali Jenis Emosi Menggunakan Recurrent Neural Network," *J. Sist. Komput. dan Inform.*, vol. 5, no. 2, p. 318, 2023, doi: 10.30865/json.v5i2.7162.
- [10] Y. P. B. Sagala, R. Samosir, and Y. Laia, "Investigasi Peningkatan Penggunaan Narkoba di Kota Medan Menggunakan Metode Support Vector Machine (SVM)," *Komputasi Berkinerja Tinggi*, vol. 6, no. 3, pp. 1071–1079, 2024.
- [11] Amna *et al.*, *Data Mining*. Padang: PT Global Eksekutif Teknologi, 2023.
- [12] N. Nadiyah, N. H. I. Arifin, and A. Karim, "Penerapan Algoritma K-Means Untuk Clustering Penilaian Layanan Berdasarkan Indeks Kepuasan Mahasiswa Universitas Nurul Jadid," *J. Adv. Res. Inform.*, vol. 2, no. 2, pp. 23–30, 2024, doi: 10.24929/jars.v2i2.3431.
- [13] W. Alfian and T. Hidayat, "Analisis Clustering Pegawai Berdasarkan Tingkat Kedisiplinan Menggunakan Algoritma K-Means dan Davies-Bouldin Index," *J. Electr. Eng. Comput.*, vol. 6, no. 2, pp. 437–448, 2024, doi: 10.33650/jeeecom.v4i2.
- [14] B. G. B. Yapen, A. Faisol, and Y. A. Pranoto, "Penerapan Algoritma K-Means Clustering Untuk Pengelompokan Wilayah Rawan Bencana Alam Kabupaten Biak Numfor," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 2, pp. 1221–1228, 2024, doi: 10.36040/jati.v8i2.9084.
- [15] A. Basri, A. Mubarak, H. K. Siradjuddin, and S. Do Abdullah, "Penentuan Jumlah Klaster Terbaik pada K-Means dalam Melihat Pola Pengelompokan Data Mahasiswa yang Telah Lulus," *JATI (Jurnal Jar. dan Teknol. Inf.)*, vol. 3, no. 1, pp. 80–86, 2023, doi: 00.0000/jati.
- [16] R. Rianti, R. Andarsyah, and R. M. Awangga, "Penerapan PCA dan Algoritma Clustering untuk Analisis Mutu Perguruan Tinggi di LLDIKTI Wilayah IV," *Nuansa Inform.*, vol. 18, no. 2, pp. 67–77, 2024, doi: 10.25134/ilkom.v18i2.211.
- [17] F. D. Marleny, *Pengolahan Citra Digital Menggunakan Python*. Jawa Tengah: CV. Pena Persada, 2021.
- [18] M. H. Widiyanto, R. Mayasari, and G. Garno, "Implementasi Time Series Pada Data Penjualan Di Gaikindo Menggunakan Algoritma Seasonal Arima," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 7, no. 3, pp. 1501–1506, 2023, doi: 10.36040/jati.v7i3.6879.

- [19] H. Ghodang and Hantono, *Metode Penelitian Kuantitatif Konsep Dasar & Aplikasi Analisis Regresi Dengan Jalur SPSS*. Medan: PT. Penerbit Mitra Grup, 2020.
- [20] F. Rachmawati, J. Jaenudin, N. B. Ginting, and P. Laksono, "Machine Learning for the Model Prediction of Final Semester Assessment (FSA) using the Multiple Linear Regression Method," *J. Tek. Inform.*, vol. 17, no. 1, pp. 1–9, 2024, doi: 10.15408/jti.v17i1.28652.
- [21] A. Andi, C. Juliandy, and D. David, "Clustering Analysis of Tweets About COVID-19 Using the K-Means Algorithm," *Sinkron*, vol. 8, no. 1, pp. 543–533, 2023, doi: 10.33395/sinkron.v8i1.12145.
- [22] A. Zulqifar, A. Wahyudi, A. Hanif, and R. Samsinar, "Prediksi Harga Masuk dan Rating Wisata di Pulau Jawa dengan Metode K-Means & DBSCAN," in *Prosiding Seminar Nasional Teknologi dan Sains*, 2025, vol. 4, pp. 667–673.