

Implementasi Algoritma Naïve Bayes dalam Identifikasi Kejang Epilepsi dengan Menggunakan Sinyal EEG

Agrifa Insani Napitupulu*, Dhanny Rukmana Manday, William Owen Wijaya, Yennimar, Mardi Turnip

Fakultas Sains dan Teknologi, Teknik Informatika, Universitas Prima Indonesia, Medan, Indonesia

Email: ¹*agrifainsaninapit@gmail.com, ²dhannyrukmanamanday@unprimdn.ac.id,

³williamowenwijaya191204@gmail.com, ⁴yennimar@unprimdn.ac.id, ⁵marditurnip@unprimdn.ac.id

Email Penulis Korespondensi: agrifainsaninapit@gmail.com*

Submitted: 07/08/2025; Accepted: 20/08/2025; Published: 08/09/2025

Abstrak—Epilepsi merupakan gangguan neurologis kronis yang ditandai dengan aktivitas listrik abnormal di otak, yang dapat dideteksi melalui sinyal elektroensefalogram (EEG). Deteksi dini epilepsi sangat penting untuk mencegah dampak yang lebih serius terhadap kesehatan penderita. Penelitian ini bertujuan untuk mengklasifikasikan kondisi epileptik dan non-epileptik berdasarkan data EEG menggunakan algoritma Naive Bayes. Dataset yang digunakan berasal dari *Kaggle* dan terdiri dari 11.500 sampel sinyal EEG dengan 178 fitur numerik. Data mengalami tahap pra-pemrosesan berupa binarisasi label, normalisasi, serta reduksi dimensi menggunakan Principal Component Analysis (PCA). Selanjutnya, dilakukan pelatihan dan pengujian model Gaussian Naive Bayes dengan proporsi data latih dan uji sebesar 80:20. Hasil evaluasi menunjukkan bahwa algoritma Naive Bayes mampu memberikan performa yang baik dengan akurasi sebesar 96%, precision dan recall masing-masing sebesar 90% untuk kelas epileptik, serta nilai F1-score sebesar 90%. Temuan ini mengindikasikan bahwa model ini cukup andal dan efisien untuk klasifikasi sinyal EEG, meskipun dengan keterbatasan asumsi independensi antar fitur. Dengan demikian, algoritma Naive Bayes dapat menjadi solusi awal dalam pengembangan sistem deteksi dini epilepsi berbasis machine learning.

Kata Kunci: EEG;PCA;Epilepsi;Naive Bayes;Machine Learning

Abstract—Epilepsy is a chronic neurological disorder characterized by abnormal electrical activity in the brain, which can be detected through electroencephalogram (EEG) signals. Early detection of epilepsy is crucial to prevent more serious impacts on the patient's health. This study aims to classify epileptic and non-epileptic conditions based on EEG data using the Naive Bayes algorithm. The dataset used is from *Kaggle* and consists of 11,500 EEG signal samples with 178 numerical features. The data underwent preprocessing stages including label binarization, normalization, and dimensionality reduction using Principal Component Analysis (PCA). Subsequently, a Gaussian Naive Bayes model was trained and tested with an 80:20 split for training and testing data. Evaluation results show that the Naive Bayes algorithm achieved good performance with an accuracy of 96%, precision and recall of 90% respectively for the epileptic class, and an F1-score of 90%. These findings indicate that the model is reliable and efficient enough for EEG signal classification, despite the limitation of the independence assumption between features. Thus, the Naive Bayes algorithm can serve as an initial solution in the development of a machine learning-based early epilepsy detection system.

Keywords: EEG;PCA;Epilepsy;Naive Bayes;Machine Learning

1. PENDAHULUAN

Epilepsi merupakan salah satu gangguan neurologis kronis yang ditandai dengan aktivitas listrik abnormal di otak, yang dapat berdampak signifikan pada kualitas hidup penderitanya [1]. Gangguan ini sering kali bersifat tidak terduga dan dapat menimbulkan risiko kecelakaan, penurunan fungsi kognitif, bahkan stigma sosial. [2] Deteksi dini dan diagnosis yang akurat menjadi langkah krusial untuk membantu pasien mendapatkan penanganan yang tepat. Namun, dalam praktiknya, proses identifikasi kejang epilepsi masih memiliki tantangan, terutama karena kemunculan gejala yang bervariasi antar individu dan keterbatasan metode manual dalam interpretasi sinyal EEG. [3][4] Oleh karena itu, dibutuhkan solusi berbasis teknologi yang mampu mendeteksi kondisi epileptik secara cepat, akurat, dan otomatis.

Salah satu pendekatan yang potensial adalah pemanfaatan metode machine learning (ML) dan deep learning (DL) dalam analisis sinyal elektroensefalogram (EEG), yang mampu mengenali pola-pola khas kejang epilepsi secara sistematis [5][6][7]. EEG sendiri adalah alat diagnostik non-invasif yang digunakan untuk merekam aktivitas listrik otak melalui sensor pada permukaan kulit kepala [8]. Data EEG mengandung informasi fisiologis yang esensial dan telah digunakan untuk mendeteksi berbagai gangguan neurologis, termasuk penyakit Alzheimer, gangguan tidur, trauma kepala, dan cedera otak lainnya [9].

Berbagai penelitian telah dilakukan untuk mendeteksi kejang epilepsi berbasis EEG. Fitriani et al. (2025) menggunakan metode Long Short-Term Memory (LSTM) dalam mendeteksi pra-kejang dan menunjukkan akurasi yang cukup tinggi dalam klasifikasi sinyal EEG [10]. Sementara itu, Dastgoshadeh dan Rabiei (2023) mengembangkan pendekatan dengan fitur entropi dan ensemble learning, menghasilkan deteksi yang lebih andal untuk sinyal non-linier [11][12]. Penelitian oleh Ahmad et al. (2022) dan Nafea & Ismail (2022) menyajikan tinjauan sistematis mengenai teknik pembelajaran mesin dan deep learning untuk deteksi kejang epilepsi, dengan penekanan pada kekuatan kombinasi fitur dan arsitektur model [13][14]. Lutvi Azizah (2023) mengembangkan sistem klasifikasi berbasis EEG untuk mendeteksi epilepsi secara otomatis, meskipun masih menghadapi tantangan dalam peningkatan presisi [15]. Di sisi lain, Johan (2021) mengaplikasikan algoritma K-Means Clustering dalam


sistem pakar untuk deteksi epilepsi selama masa pandemi, dengan fokus pada kemudahan integrasi sistem dalam kondisi terbatas [16].

Kendati demikian, masih terdapat beberapa celah (gap) dalam penelitian-penelitian sebelumnya. Banyak studi yang berfokus pada model yang kompleks namun tidak mempertimbangkan efisiensi komputasi dan implementasi nyata di fasilitas layanan kesehatan, terutama di wilayah dengan keterbatasan sumber daya. Beberapa penelitian juga belum mengevaluasi performa model secara menyeluruh dengan menggunakan metrik evaluasi standar seperti akurasi, sensitivitas, spesifisitas, serta confusion matrix sebagai tolok ukur performa klasifikasi [17][18][19]. Selain itu, penggunaan metode yang lebih ringan namun tetap akurat seperti Naïve Bayes masih jarang dieksplorasi secara mendalam pada konteks data EEG epilepsi, padahal metode ini dikenal efisien dan interpretatif.[20]

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengklasifikasikan kondisi epileptik dan non-epileptik berdasarkan sinyal EEG dengan menggunakan algoritma Naïve Bayes. Dengan mengevaluasi performa model melalui confusion matrix dan metrik lainnya, diharapkan penelitian ini dapat memberikan alternatif metode deteksi epilepsi yang lebih sederhana, cepat, dan tetap akurat. Harapannya, hasil dari penelitian ini dapat menjadi kontribusi dalam pengembangan sistem diagnosis epilepsi berbasis EEG yang dapat diterapkan di berbagai fasilitas kesehatan, khususnya di daerah dengan akses terbatas terhadap teknologi canggih.

2. METODOLOGI PENELITIAN

Penelitian ini mengikuti pendekatan eksperimen komputasional yang terdiri dari tahapan: (1) pemilihan dataset, (2) pra-pemrosesan data, (3) eksplorasi data, (4) reduksi dimensi menggunakan PCA, (5) pelatihan model Naïve Bayes, dan (6) evaluasi model dengan metrik klasifikasi. Diagram alur penelitian ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

2.1 Dataset

Dataset yang digunakan adalah Epileptic Seizure Recognition yang tersedia di platform Kaggle. Dataset ini dipilih karena:

- Ukuran data besar dan seimbang untuk eksperimen awal: terdiri dari 11.500 sampel dengan 178 fitur numerik.
- Telah digunakan secara luas dalam penelitian epilepsi, sehingga hasil dapat dibandingkan dengan studi sebelumnya.
- Kualitas data terjamin: data bersih, berlabel, dan berasal dari sumber terpercaya.
- Representasi masalah nyata: sinyal EEG direkam dengan variasi kondisi otak, memungkinkan model untuk mempelajari pola epileptik dan non-epileptik.

Dataset ini awalnya memiliki lima kelas aktivitas otak, di mana kelas 1 merepresentasikan kondisi epileptik (seizure), sedangkan kelas 2 hingga 5 merupakan kondisi non-epileptik. Untuk keperluan klasifikasi biner, label direkayasa ulang menjadi:

- a. 1 = epileptik
- b. 0 = non-epileptik (gabungan kelas 2–5).

Distribusi data ditunjukkan pada Tabel 1.

Tabel 1. Distribusi Data Setelah Binarisasi

Kelas	Jumlah Sampel
Epileptik (1)	2300
Non-epileptik (0)	9200

Ketidakseimbangan kelas sebesar 1:4 diperhatikan dalam tahap evaluasi untuk menghindari bias terhadap kelas mayoritas.


2.2 Pra-pemrosesan Data

Tahapan pra-pemrosesan meliputi:

1. Menghapus kolom tidak relevan (misalnya ‘Unnamed’).
2. Penanganan missing value dengan dropna().
3. Binarisasi label menjadi dua kelas.
4. Standardisasi fitur menggunakan StandardScaler agar setiap fitur memiliki mean 0 dan deviasi standar 1.
5. Reduksi dimensi dengan PCA untuk menurunkan kompleksitas data dan mengatasi korelasi antar fitur.

2.3 Reduksi Dimensi dengan PCA

Principal Component Analysis (PCA) diterapkan untuk mereduksi dimensi dari 178 fitur menjadi 30 komponen utama. Pemilihan jumlah komponen didasarkan pada analisis kurva variansi kumulatif (scree plot), di mana 30 komponen mampu mempertahankan 95% variansi total. Dengan demikian, kompleksitas berkurang signifikan tanpa kehilangan informasi penting. Gambar 2 menampilkan kurva variansi kumulatif PCA.




Gambar 2. Scree plot PCA dengan garis threshold 95% variansi

2.4 Pembagian Data

Data dibagi menjadi dua subset:

- a. Data latih (80%)
- b. Data uji (20%)

Pembagian dilakukan secara stratified split agar distribusi kelas tetap seimbang antara data latih dan uji. Distribusi data ditampilkan pada Gambar 3.



Gambar 3. Distribusi Data Latih dan Uji

2.5 Penanganan Ketidakseimbangan Data

Distribusi data yang tidak seimbang (epileptik lebih sedikit) dapat mempengaruhi model, terutama pada metrik recall kelas minoritas. Untuk mengatasi hal ini:

- Pembagian data menggunakan stratified split agar proporsi kelas tetap konsisten di data latih dan uji.
- Penggunaan metrik tambahan seperti F1-score dan confusion matrix agar performa model tidak hanya diukur dari akurasi.
- Alternatif strategi (opsional): oversampling dengan SMOTE atau under-sampling dapat dipertimbangkan, meskipun dalam penelitian ini hanya digunakan evaluasi berbasis metrik seimbang.

2.6 Algoritma Naïve Bayes

Naïve Bayes adalah algoritma klasifikasi probabilistik yang mengasumsikan independensi antar fitur, dengan perhitungan berbasis Teorema Bayes:

$$P(C | X) = (P(X | C) \cdot P(C)) / P(X) \quad (1)$$

Dalam penelitian ini digunakan varian Gaussian Naïve Bayes, yang mengasumsikan distribusi normal pada fitur. Probabilitas dihitung dengan:

$$P(x_i | C) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot e^{-\frac{(x_i - \mu)^2}{2\sigma^2}} \quad (2)$$

di mana:

- μ = rata-rata fitur
- σ^2 = varians fitur

2.7 Evaluasi Model

Model dievaluasi menggunakan:

- Akurasi, Precision, Recall, F1-score
- Confusion Matrix
- Macro dan Weighted Average untuk mengatasi pengaruh ketidakseimbangan kelas.

Selain pembagian data 80% latih – 20% uji, penelitian ini juga menggunakan validasi silang (k-fold cross-validation) dengan k = 5 untuk meningkatkan reliabilitas hasil dan mengurangi bias akibat pembagian data tunggal. Nilai rata-rata metrik dari k-fold akan dilaporkan sebagai hasil akhir.


3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan Model

Model Gaussian Naïve Bayes dilatih menggunakan data hasil reduksi dimensi PCA (30 komponen). Evaluasi dilakukan menggunakan data uji sebesar 20% dari total dataset. Hasil pengujian menunjukkan performa sebagai berikut:

- Akurasi: 96%
- Precision (Epileptik): 90%
- Recall (Epileptik): 90%
- F1-score (Epileptik): 90%

Selain metrik tersebut, visualisasi performa model ditunjukkan melalui Confusion Matrix pada Gambar 4.



Gambar 4. Confusion Matrix

3.2 Deskripsi Dataset

Dataset Epileptic Seizure Recognition yang digunakan dalam penelitian ini berjumlah 11.500 sampel, dengan masing-masing sampel memiliki 178 fitur numerik. Setelah dilakukan binarisasi label, diperoleh:

- Epileptik (1): 2.300 sampel
- Non-epileptik (0): 9.200 sampel

Distribusi ini menunjukkan ketidakseimbangan kelas, dengan kelas non-epileptik empat kali lebih banyak. Oleh karena itu, evaluasi model tidak hanya mengandalkan akurasi, tetapi juga metrik seperti precision, recall, dan F1-score untuk menilai performa pada kelas minoritas.

3.3 Evaluasi Kinerja Model

Model Gaussian Naïve Bayes dievaluasi menggunakan pembagian data 80% latih dan 20% uji dengan tambahan validasi silang 5-fold. Hasil pengujian pada data uji ditunjukkan pada Tabel 2.

Tabel 2. Hasil Evaluasi Model

Kelas	Precision	Recall	F1-Score	Support
Non-epileptik	0.97	0.97	0.97	2.752
Epileptik	0.90	0.90	0.90	698
Akurasi Total			0.96	3.450

Confusion Matrix (Gambar 4):

- a. True Positive (TP): 628
- b. False Negative (FN): 70
- c. True Negative (TN): 2.679
- d. False Positive (FP): 73

3.4 Interpretasi Klinis dari Metrik

- a. False Negative (FN = 70): 70 kasus epileptik salah diklasifikasikan sebagai non-epileptik. Ini berbahaya secara klinis karena pasien epilepsi dapat luput dari pengobatan. Oleh karena itu, recall untuk kelas epileptik sangat penting.
- b. False Positive (FP = 73): 73 kasus non-epileptik terdeteksi salah sebagai epileptik. Ini lebih dapat diterima dibanding FN, meskipun dapat menyebabkan diagnosis berlebihan.
- c. Recall epileptik = 90% berarti 9 dari 10 pasien epilepsi dapat terdeteksi, yang cukup baik untuk aplikasi klinis awal.
- d. Precision epileptik = 90% mengurangi risiko alarm palsu yang berlebihan.

3.5 Analisis Kelebihan dan Keterbatasan

Kelebihan Naïve Bayes:

- a. Cepat, efisien, dan cocok untuk data berdimensi tinggi.
- b. Tidak memerlukan tuning parameter kompleks.

Keterbatasan:

- a. Asumsi independensi antar fitur sering tidak terpenuhi dalam sinyal EEG yang sangat korelatif.
- b. PCA membantu mengurangi dampak keterbatasan ini dengan:
 - a) Menghapus korelasi antar fitur.
 - b) Mereduksi dimensi menjadi representasi yang lebih orthogonal.

3.6 Perbandingan dengan Penelitian Sebelumnya

Tabel 3. Perbandingan dengan Studi Terdahulu

Peneliti	Metode	Akurasi	Catatan
Siddiqui et al. [4]	Naïve Bayes	95.63%	Tidak menggunakan PCA
Lestari et al. [11]	NB, KNN, RF	~89%	Performa NB lebih rendah
Fitrani et al. [7]	LSTM	97%	Kompleks, butuh komputasi besar
Penelitian ini	NB + PCA	96%	Ringan & akurat dengan PCA

Dari tabel terlihat bahwa integrasi PCA meningkatkan akurasi Naïve Bayes dibanding studi NB tanpa PCA dan mendekati performa model deep learning (LSTM), tetapi dengan kompleksitas jauh lebih rendah.

3.7 Implikasi Praktis

Hasil ini memiliki potensi besar untuk:

- a. Integrasi ke sistem EEG real-time: karena Naïve Bayes sangat cepat, dapat dipasang pada perangkat portabel.
- b. Aplikasi di fasilitas kesehatan terbatas: hemat sumber daya dibanding deep learning.
- c. Sistem pendukung diagnosis: membantu dokter mengenali pola epileptik lebih cepat.

4. KESIMPULAN

Penelitian ini berhasil mencapai tujuan yang ditetapkan, yaitu mengklasifikasikan sinyal EEG ke dalam kondisi epileptik dan non-epileptik menggunakan algoritma Naïve Bayes yang dioptimalkan dengan metode Principal Component Analysis (PCA). Hasil pengujian menunjukkan bahwa model yang dikembangkan memiliki performa tinggi, dengan akurasi sebesar 96%, serta nilai precision dan recall masing-masing sebesar 90% untuk kelas epileptik, dan F1-score sebesar 90%. Temuan ini menunjukkan bahwa pendekatan Naïve Bayes yang sederhana, jika dikombinasikan dengan PCA, dapat menjadi solusi efektif untuk deteksi epilepsi secara otomatis. Kontribusi utama dari penelitian ini adalah pembuktian bahwa kombinasi metode probabilistik sederhana dengan teknik reduksi dimensi mampu mencapai akurasi yang kompetitif dibandingkan model kompleks seperti deep learning, namun dengan kebutuhan komputasi yang jauh lebih ringan. Hal ini membuka peluang untuk implementasi sistem pada aplikasi real-time, termasuk integrasi dengan perangkat EEG portabel di fasilitas kesehatan yang memiliki keterbatasan sumber daya.

REFERENCES

- [1] A. Madani *et al.*, “Peningkatan Pengetahuan Mengenai Epilepsi Pada Pasien Poli Saraf Rumah Sakit Ulin Banjarmasin,” *J. Pengabd. Masy. Panacea*, vol. 2, no. 2, hal. 126–132, 2024.
- [2] W. Zeng, L. Shan, B. Su, dan S. Du, “Epileptic seizure detection with deep EEG features by convolutional neural network and shallow classifiers,” *Front. Neurosci.*, vol. Volume 17, 2023, [Daring]. Tersedia pada: <https://www.frontiersin.org/journals/neuroscience/articles/10.3389/fnins.2023.1145526>
- [3] E. Abdullayeva dan H. K. Örnek, “Diagnosing Epilepsy from EEG Using Machine Learning and Welch Spectral Analysis,” *Trait. du Signal*, vol. 41, no. 2, 2024.
- [4] S. Noertjahjani, “Rancang Bangun Klasifikasi Sinyal Elektroensefalografi Pada Kasus Epilepsi Dengan Random forest GSO,” *J. ICT Inf. Commun. Technol.*, 2023.
- [5] N. U. R. S. B. A. AZIZ, “ELECTROENCEPHALOGRAPHY SIGNAL CLASSIFICATION USING NEURAL NETWORK, DECISION TREE AND ENSEMBLE BAGGED TREE FOR EPILEPSY DISEASE,” 2022.
- [6] M. Kurniawan, A. Rachman, dan A. Pakarbudi, “Review Pemanfaatan Data Electroencephalogram (EEG) dengan metode Convolution Neural Network,” *INTEGER J. Inf. Technol.*, vol. 6, no. 2, 2021.
- [7] P. Grant dan M. Z. Islam, “EEG Signal Processing using Wavelets for Accurate Seizure Detection through Cost Sensitive Data Mining,” *arXiv Prepr. arXiv2109.13818*, 2021.
- [8] D. R. Manday, A. C. Sembiring, N. Lumbantoruan, A. S. Ginting, R. M. Simanjuntak, dan D. Sitanggang, “Application Of Decision Tree Algorithm In Classifying The Level Of Impulsivity In EEG Signals,” in *2024 2nd International Conference on Technology Innovation and Its Applications (ICTIIA)*, IEEE, 2024, hal. 1–6.
- [9] O. Nurdiawan, F. Fathurrohman, dan A. Faqih, “Optimisasi Model Backpropagation untuk Meningkatkan Deteksi Kejang Epilepsi pada Sinyal Electroencephalogram,” *Inf. Syst. Educ. Prof. J. Inf. Syst.*, vol. 9, no. 2, hal. 151–160, 2024.
- [10] A. S. Fitriani, U. khoirun Nisak, E. Agustin, dan A. T. Zahputra, “Deteksi prakejang pada pasien epilepsi berdasarkan rekam sinyal EEG menggunakan metode LSTM,” *INTEGER J. Inf. Technol.*, vol. 10, no. 1, 2025.
- [11] M. Dastgoshadeh dan Z. Rabiei, “Detection of epileptic seizures through EEG signals using entropy features and ensemble learning,” *Front. Hum. Neurosci.*, vol. 16, hal. 1084061, 2022, doi: 10.3389/fnhum.2022.1084061.
- [12] M. Dastgoshadeh dan Z. Rabiei, “Detection of epileptic seizures through EEG signals using entropy features and ensemble learning,” *Front. Hum. Neurosci.*, vol. Volume 16, 2023, [Daring]. Tersedia pada: <https://www.frontiersin.org/journals/human-neuroscience/articles/10.3389/fnhum.2022.1084061>
- [13] I. Ahmad *et al.*, “EEG-Based Epileptic Seizure Detection via Machine/Deep Learning Approaches: A Systematic Review,” *Comput. Intell. Neurosci.*, vol. 2022, hal. 6486570, 2022, doi: 10.1155/2022/6486570.
- [14] M. S. Nafea dan Z. H. Ismail, “Supervised Machine Learning and Deep Learning Techniques for Epileptic Seizure Recognition Using EEG Signals—A Systematic Literature Review,” *Bioengineering*, vol. 9, no. 12. 2022. doi: 10.3390/bioengineering9120781.
- [15] N. L. A. Nuril Lutvi Azizah, “Unplag Deteksi Penyakit Epilepsi Melalui Sinyal EEG,” 2023.
- [16] T. M. Johan, “Sistem Pendeteksi Epilepsi Dengan Algoritma K-Means Clustering Sebagai Pendeteksi Penyakit Berbasis Sistem Pakar Pada Masa Pandemi Covid-19,” *J. Tika*, vol. 6, no. 02, hal. 173–183, 2021.
- [17] F. P. Lestari, M. Haekal, R. Edmi Edison, F. Ravi Fauzy, S. Nurul Khotimah, dan F. Haryanto, “Epileptic Seizure Detection in EEGs by Using Random Tree Forest, Naïve Bayes and KNN Classification,” *J. Phys. Conf. Ser.*, vol. 1505, no. 1, hal. 12055, 2020, doi: 10.1088/1742-6596/1505/1/012055.
- [18] S. A. Karthik, K. N. Bharath, B. R. Ramji, K. Puttegowda, B. Aruna, dan D. S. S. Kumar, “Enhanced EEG Signal Processing for Accurate Epileptic Seizure Detection,” *SN Comput. Sci.*, vol. 6, no. 6, hal. 608, 2025, doi: 10.1007/s42979-025-04148-1.
- [19] N. N. Sabilla, M. Fatchan, dan A. Aguswin, “MENGOPTIMALKAN KLASIFIKASI SINYAL ELECTROENCEPHALOGRAM UNTUK MENDETEKSI KEJANG EPILEPSI DENGAN BACKPROPAGATION NEURAL NETWORK,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 2, hal. 3501–3509, 2025.
- [20] M. K. Siddiqui, R. Morales-Menendez, X. Huang, dan N. Hussain, “A review of epileptic seizure detection using machine learning classifiers,” *Brain Informatics*, vol. 7, no. 1, hal. 5, 2020, doi: 10.1186/s40708-020-00105-1.