

Klasifikasi Gangguan Autisme Berdasarkan Dataset Perilaku Anak Menggunakan Metode K-Nearest Neighbor (KNN)

Muhamad Ihsan Ashari*¹, Riky Susanto²

¹Sistem Informasi, Universitas Pamulang, Jl. Raya Puspittek, Tangerang Selatan 15310, Indonesia

²Teknik Informatika, Universitas Pamulang, Jl. Raya Puspittek, Tangerang Selatan 15310, Indonesia

e-mail: dosen03154@unpam.ac.id* ; dosen02663@unpam.ac.id

Abstrak

Deteksi dini Gangguan Spektrum Autisme (Autism Spectrum Disorder/ASD) berperan penting dalam mendukung keberhasilan intervensi perkembangan anak, namun proses skrining awal masih banyak bergantung pada observasi manual yang berpotensi menyebabkan keterlambatan diagnosis. Penelitian ini bertujuan mengembangkan model klasifikasi berbasis data perilaku anak untuk mendukung skrining dini ASD menggunakan algoritma K-Nearest Neighbor (KNN). Data yang digunakan berasal dari Toddler Autism Dataset Juli 2018 yang terdiri atas 1.054 sampel dan 19 variabel. Kinerja model dievaluasi menggunakan metrik akurasi, presisi, recall, dan confusion matrix. Hasil penelitian menunjukkan bahwa model KNN mencapai akurasi sebesar 97,16% dengan nilai presisi dan recall yang tinggi pada kedua kelas. Temuan ini menunjukkan bahwa algoritma KNN berpotensi menjadi pendekatan komputasi yang sederhana dan efektif untuk mendukung skrining dini ASD berbasis data perilaku anak.

Kata kunci: Gangguan Spektrum Autisme, klasifikasi perilaku, deteksi dini, K-Nearest Neighbor, machine learning.

Abstract

Early detection of Autism Spectrum Disorder (ASD) plays an important role in supporting the success of developmental interventions in children; however, the early screening process still largely relies on manual observation, which may lead to delays in diagnosis. This study aims to develop a classification model based on children's behavioral data to support early ASD screening using the K-Nearest Neighbor (KNN) algorithm. The data were obtained from the Toddler Autism Dataset July 2018, consisting of 1,054 samples and 19 variables. Model performance was evaluated using accuracy, precision, recall, and a confusion matrix. The results show that the KNN model achieved an accuracy of 97.16% with high precision and recall for both classes. These findings indicate that the KNN algorithm has strong potential as a simple and effective computational approach to support early ASD screening based on children's behavioral data.

Keywords: Autism Spectrum Disorder, behavioral classification, early detection, K-Nearest Neighbor, machine learning.

1. PENDAHULUAN

Gangguan Spektrum Autisme (Autism Spectrum Disorder/ASD) merupakan gangguan perkembangan yang ditandai oleh keterbatasan dalam komunikasi sosial serta pola perilaku yang berulang. Deteksi dini ASD memiliki peran penting dalam mendukung keberhasilan intervensi perkembangan anak. Namun, hingga saat ini proses skrining awal masih banyak bergantung pada observasi manual oleh tenaga ahli, yang memerlukan waktu, biaya, serta ketersediaan sumber daya manusia yang terbatas, sehingga berpotensi menyebabkan keterlambatan dalam diagnosis [1]. Keterlambatan identifikasi tersebut dapat mengurangi peluang anak untuk memperoleh intervensi dini yang terbukti mampu meningkatkan perkembangan sosial, bahasa, dan kognitif [2].

Seiring dengan perkembangan teknologi, pendekatan berbasis machine learning mulai banyak diterapkan untuk mendukung deteksi dini ASD melalui analisis data perilaku anak. Berbagai penelitian telah menunjukkan bahwa algoritma klasifikasi mampu mengenali pola-pola perilaku yang berkaitan dengan gejala ASD secara lebih objektif dan terukur [3]. Meskipun demikian, sebagian besar penelitian sebelumnya menggunakan model yang relatif kompleks dan membutuhkan komputasi tinggi, sehingga kurang praktis untuk diterapkan sebagai sistem skrining sederhana di lingkungan pendidikan maupun layanan kesehatan dasar [4]. Selain itu, masih terbatas penelitian yang secara khusus mengevaluasi kinerja algoritma sederhana seperti

K-Nearest Neighbor (KNN) pada dataset perilaku anak usia dini (toddler) dengan fokus pada kemudahan implementasi dan interpretasi hasil.

Algoritma K-Nearest Neighbor merupakan metode klasifikasi non-parametrik yang bekerja berdasarkan kedekatan jarak antar data dalam ruang fitur. KNN memiliki keunggulan berupa kesederhanaan implementasi, tidak memerlukan proses pelatihan model yang kompleks, serta mampu bekerja dengan baik pada dataset berukuran menengah dan data perilaku yang bersifat heterogen [5][6]. Karakteristik tersebut menjadikan KNN sebagai kandidat metode yang potensial untuk diterapkan dalam sistem skrining dini ASD berbasis data perilaku anak.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan model klasifikasi guna mengidentifikasi potensi ASD pada anak menggunakan Toddler Autism Dataset Juli 2018 serta mengevaluasi kinerja algoritma KNN berdasarkan metrik akurasi, presisi, recall, dan confusion matrix. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan pendekatan klasifikasi yang sederhana namun akurat untuk mendukung skrining dini ASD, sekaligus memberikan dasar bagi pengembangan sistem pendukung keputusan yang aplikatif di bidang kesehatan anak.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan klasifikasi berbasis machine learning untuk mengidentifikasi kemungkinan terjadinya Gangguan Spektrum Autisme (Autism Spectrum Disorder/ASD) pada anak berdasarkan indikator perilaku [11]. Pendekatan komputasi dipilih karena mampu mengenali pola secara objektif dari data berlabel dan mendukung proses skrining dini secara lebih terukur [12]. Algoritma K-Nearest Neighbor (KNN) digunakan sebagai metode utama karena merupakan algoritma klasifikasi non-parametrik yang sederhana, mudah diimplementasikan, serta efektif dalam mengenali kemiripan antar sampel berdasarkan jarak kedekatan [13]. Selain itu, KNN tidak memerlukan asumsi khusus mengenai distribusi data, sehingga sesuai untuk dataset perilaku yang memiliki variabel campuran [14].

Data penelitian diperoleh dari Toddler Autism Dataset Juli 2018, yaitu dataset publik yang berasal dari hasil skrining perilaku anak usia dini menggunakan instrumen terstandar [16]. Dataset ini terdiri atas variabel indikator perilaku, karakteristik anak, serta informasi keluarga yang berkaitan dengan indikasi ASD. Data digunakan sebagai data sekunder tanpa melakukan pengumpulan data langsung dari responden, sehingga penelitian ini termasuk dalam kategori studi dokumen [17].

Prosedur penelitian dilakukan secara terstruktur melalui beberapa tahapan utama. Tahap pertama adalah prapemrosesan data yang meliputi pemeriksaan kelengkapan data, penghapusan atribut yang tidak relevan, serta konversi variabel kategorikal ke bentuk numerik menggunakan teknik label encoding. Tahap kedua adalah pembagian data menjadi data latih (80%) dan data uji (20%) menggunakan teknik *train-test split*. Tahap ketiga adalah normalisasi fitur menggunakan *StandardScaler* untuk menyeragamkan skala data sehingga perhitungan jarak pada KNN tidak didominasi oleh variabel tertentu. Tahap berikutnya adalah pelatihan model KNN dengan menetapkan nilai awal $k = 5$. Nilai k tersebut dipilih berdasarkan praktik umum dalam klasifikasi berbasis KNN serta pertimbangan keseimbangan antara bias dan varians, di mana nilai k yang terlalu kecil berpotensi menyebabkan *overfitting*, sedangkan nilai k yang terlalu besar dapat mengaburkan batas antar kelas [19]. Model kemudian diuji menggunakan data uji untuk menghasilkan prediksi kelas ASD atau non-ASD.

Kinerja model dievaluasi menggunakan metrik akurasi, presisi, recall, serta confusion matrix [21]. Akurasi digunakan untuk mengukur tingkat ketepatan prediksi secara keseluruhan, sedangkan presisi dan recall digunakan untuk menilai ketepatan identifikasi pada masing-masing kelas [22]. Confusion matrix digunakan untuk menggambarkan distribusi prediksi benar dan salah pada setiap kelas sehingga memberikan gambaran yang lebih rinci mengenai kemampuan model dalam membedakan anak dengan dan tanpa indikasi ASD [23].

Untuk memperjelas alur penelitian, disertakan diagram alir (flowchart) yang menggambarkan tahapan utama mulai dari pengambilan data, prapemrosesan, pembagian data, pelatihan dan evaluasi model, hingga penarikan kesimpulan [24][25]. Diagram ini bertujuan memudahkan pembaca dalam memahami keseluruhan proses klasifikasi yang dilakukan dalam penelitian.

3. HASIL DAN PEMBAHASAN

3.1.. Data Set

Dataset yang digunakan dalam penelitian ini adalah Toddler Autism Dataset Juli 2018, yang berisi data skrining perilaku anak usia dini yang diperoleh menggunakan instrumen Q-CHAT. Dataset ini terdiri atas 1.054 baris data dan 19 variabel, yang mencakup indikator perilaku yang dikodekan A1–A10, usia anak dalam satuan bulan, skor Q-CHAT, serta informasi demografis seperti jenis kelamin dan etnisitas, serta riwayat keluarga

dengan ASD. Dataset ini memiliki satu variabel target, yaitu “Class/ASD Traits”, yang menunjukkan apakah terdapat ASD (Ya) atau tidak (Tidak).

Data diperoleh dari sebuah repositori daring, sehingga penelitian ini termasuk dalam kategori penelitian data sekunder. Contoh lima baris pertama dari dataset disajikan pada tabel berikut untuk menggambarkan struktur data mentah sebelum dilakukan proses prapemrosesan.

Tabel 1. Struktur Data Mentah Sebelum Prapemrosesan

No Kasus	1	2	3	4	5
A1	0	1	1	1	1
A2	0	1	0	1	1
A3	0	0	0	1	0
A4	0	0	0	1	1
A5	0	0	0	1	1
A6	0	1	0	1	1
A7	1	1	1	1	1
A8	1	0	1	1	1
A9	0	0	0	1	1
A10	1	0	1	1	1
Usia (bulan)	28	36	36	24	20
Skor Qchat-10	3	4	4	10	9
Jenis Kelamin	Perempuan	Laki-laki	Laki-laki	Laki-laki	Perempuan
Etnis	Timur Tengah	Eropa Putih	Timur Tengah	Hispanik	Eropa Putih
Kuning (Jaundice)	Ya	Ya	Ya	Tidak	Tidak
Riwayat Keluarga ASD	Tidak	Tidak	Tidak	Tidak	Ya
Pengisi Tes	Anggota keluarga	Anggota keluarga	Anggota keluarga	Anggota keluarga	Anggota keluarga
Kelas / Ciri ASD	Tidak	Ya	Ya	Ya	Ya

Pemeriksaan terhadap struktur dataset menunjukkan bahwa seluruh variabel memiliki 1.054 nilai non-null, yang menandakan tidak adanya data yang hilang (missing data). Indikator perilaku A1–A10 merupakan variabel numerik biner (0 dan 1) dengan nilai rata-rata berkisar antara 0,40 hingga 0,64, yang menunjukkan distribusi data yang relatif seimbang. Usia anak (Age_Mons) berada pada rentang 12 hingga 36 bulan dengan nilai rata-rata sebesar 27,86 bulan, yang sesuai dengan rentang usia skrining dini autisme. Nilai Qchat-10-Score bervariasi antara 0 hingga 10 dengan rata-rata sebesar 5,21, yang menunjukkan adanya variasi tingkat indikasi ciri-ciri ASD dalam dataset.

Variabel masukan yang digunakan dalam proses klasifikasi terdiri atas indikator perilaku A1–A10 serta atribut pendukung, meliputi usia, jenis kelamin, etnisitas, riwayat penyakit kuning (jaundice), dan riwayat keluarga dengan ASD. Variabel target dalam penelitian ini adalah *Class/ASD Traits*.

3.2. Prapemrosesan, Pelatihan, dan Pengujian

Tahap prapemrosesan dilakukan untuk mempersiapkan data sebelum proses pelatihan model. Kolom-kolom yang tidak relevan dihapus, variabel kategorikal dikonversi menjadi nilai numerik menggunakan teknik *label encoding*, dan variabel fitur dinormalisasi menggunakan *StandardScaler* untuk memastikan rentang nilai yang seragam. Proses ini penting untuk meningkatkan kinerja metode KNN yang sensitif terhadap perbedaan skala data.

Dataset kemudian dibagi menjadi dua bagian, yaitu 80% sebagai data latih dan 20% sebagai data uji. Model KNN dibangun dengan menggunakan nilai awal $k = 5$ sebagai parameter. Model dilatih menggunakan data latih dan selanjutnya digunakan untuk memprediksi kelas pada data uji. Pemilihan nilai k didasarkan pada praktik umum dalam klasifikasi berbasis jarak serta untuk mencegah terjadinya *overfitting* pada dataset berukuran menengah.

3.3. Model KNN

Model yang dibangun mencapai tingkat akurasi sebesar 97,16%, yang menunjukkan bahwa sebagian besar hasil prediksi sesuai dengan label sebenarnya. Metrik evaluasi untuk masing-masing kelas disajikan dalam laporan berikut:

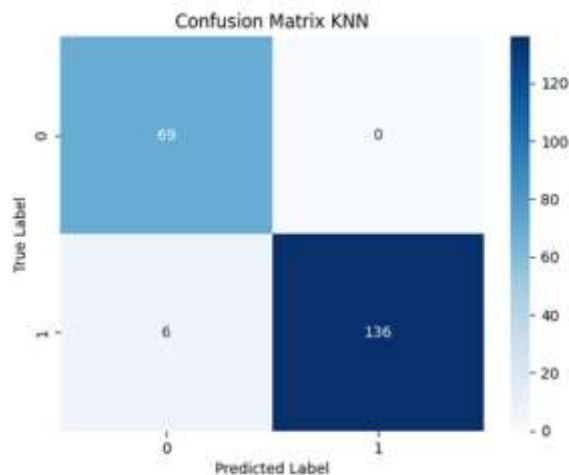
Tabel 2. Per-class evaluation metrics

Class / Metrics	Precision	Recall	F1-Score	Support
Class 0	0,92	1	0,96	69
Class 1	1	0,96	0,98	142
Accuracy			0,97	211
Macro Average	0,96	0,98	0,97	211
Weighted Average	0,97	0,97	0,97	211

Model KNN menunjukkan kinerja klasifikasi yang sangat baik dengan mencapai tingkat akurasi sebesar 97% dari total 211 sampel. Hasil evaluasi per kelas menunjukkan bahwa Kelas 0 memperoleh nilai presisi sebesar 0,92 dan recall sebesar 1,00, yang mengindikasikan bahwa model berhasil mengidentifikasi seluruh data Kelas 0 tanpa adanya kesalahan negatif (false negative), meskipun masih terdapat sejumlah kecil kesalahan positif (false positive). Sementara itu, Kelas 1 memperoleh nilai presisi sebesar 1,00 dan recall sebesar 0,96, yang berarti tidak terdapat prediksi yang salah untuk Kelas 1, namun sebagian kecil data Kelas 1 belum terdeteksi sebagai kelas yang benar. Nilai F1-score yang tinggi pada kedua kelas, yaitu masing-masing sebesar 0,96 dan 0,98, mencerminkan keseimbangan yang kuat antara presisi dan recall. Selain itu, nilai rata-rata makro (macro average) dan rata-rata tertimbang (weighted average) sebesar 0,97 menunjukkan bahwa model mempertahankan kinerja yang konsisten meskipun terdapat ketidakseimbangan jumlah sampel antar kelas. Secara keseluruhan, hasil evaluasi ini menegaskan bahwa model KNN memberikan kinerja klasifikasi yang sangat efektif dan stabil pada dataset yang digunakan.

3.4. Evaluasi Model

Berdasarkan hasil evaluasi, model KNN menunjukkan kinerja klasifikasi yang tinggi dengan tingkat akurasi sebesar 97,16%. Tingginya akurasi model KNN diduga disebabkan oleh karakteristik dataset yang memiliki indikator perilaku biner yang jelas serta pola pemisahan kelas yang relatif tegas. Selain itu, proses normalisasi fitur membantu memastikan bahwa perhitungan jarak antar sampel tidak didominasi oleh variabel tertentu, sehingga meningkatkan kualitas klasifikasi. Hasil klasifikasi secara visual disajikan menggunakan confusion matrix, sebagaimana ditunjukkan pada Gambar 1.




Gambar 1. Confusion Matrix

Gambar 1. Confusion matrix menunjukkan bahwa model berhasil mengklasifikasikan seluruh sampel Kelas 0 (tanpa indikasi ASD) dengan benar sebanyak 69 data, serta mengklasifikasikan dengan benar 136 sampel dari Kelas 1. Terdapat 6 sampel dari Kelas 1 yang salah diklasifikasikan sebagai Kelas 0. Hasil ini menunjukkan bahwa model memiliki kemampuan deteksi yang kuat, khususnya dalam menjaga keseimbangan antara kesalahan positif palsu (false positive) dan negatif palsu (false negative).

3.5. Pemilihan Nilai K Optimal Berdasarkan Tingkat Kesalahan (Error Rate)

Selain evaluasi awal dengan menggunakan nilai $k = 5$, dilakukan pula pengujian tingkat kesalahan (*error rate*) untuk berbagai nilai k dalam rentang 1 hingga 20. Hasil evaluasi tersebut divisualisasikan pada Gambar 2.



Gambar 2. Error Rate Graph

Gambar 2. Grafik menunjukkan bahwa nilai kesalahan (error) berfluktuasi, namun cenderung lebih stabil pada rentang nilai $k = 5-15$, dengan tingkat kesalahan terendah terjadi pada $k = 19$. Hasil ini menunjukkan bahwa pemilihan nilai k yang lebih besar berpotensi meningkatkan kemampuan generalisasi model, meskipun nilai $k = 5$ tetap memberikan kinerja yang sangat efektif dan konsisten sehingga digunakan sebagai konfigurasi utama dalam penelitian ini.

Visualisasi pada Gambar 1 dan Gambar 2 memperkuat hasil evaluasi model. Confusion matrix menunjukkan bahwa model lebih sering melakukan kesalahan pada kelas positif (anak dengan indikasi ASD), meskipun jumlah kesalahan klasifikasi tersebut relatif kecil. Sementara itu, grafik error rate menunjukkan bahwa peningkatan nilai k berpotensi meningkatkan kemampuan generalisasi model dan oleh karena itu dapat dipertimbangkan dalam penelitian selanjutnya untuk mengurangi tingkat kesalahan negatif palsu (false negative).

4. KESIMPULAN

Penelitian ini menunjukkan bahwa algoritma K-Nearest Neighbor (KNN) dapat digunakan secara efektif untuk mengklasifikasikan kemungkinan terjadinya Gangguan Spektrum Autisme (Autism Spectrum Disorder/ASD) pada anak usia dini berdasarkan data perilaku. Model yang dibangun mencapai tingkat akurasi sebesar 97,16% dengan nilai presisi dan recall yang tinggi pada kedua kelas, sehingga menegaskan kemampuan KNN dalam mengenali pola perilaku yang relevan sebagai indikator ASD.

Secara praktis, temuan ini menunjukkan bahwa pendekatan berbasis jarak seperti KNN berpotensi diterapkan sebagai bagian dari sistem pendukung keputusan bagi tenaga kesehatan, pendidik, maupun platform digital untuk memfasilitasi skrining dini ASD secara objektif, cepat, dan terstandar sebelum dilakukan pemeriksaan klinis lanjutan.

Meskipun demikian, penelitian ini memiliki beberapa keterbatasan, antara lain penggunaan data sekunder dari satu sumber serta variabel perilaku yang bersifat biner sehingga variasi perilaku yang lebih kompleks belum sepenuhnya terwakili. Oleh karena itu, penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih beragam, mengintegrasikan fitur perilaku yang lebih kaya, menerapkan penyesuaian hiperparameter (hyperparameter tuning) untuk mengoptimalkan nilai k , serta membandingkan kinerja KNN dengan algoritma lain seperti Support Vector Machine, Random Forest, atau Neural Network guna mengembangkan model skrining ASD yang lebih komprehensif, adaptif, dan aplikatif.

DAFTAR PUSTAKA

- [1] R. Agrawal and R. Agrawal, "Explainable AI in early autism detection: a literature review of interpretable machine learning approaches," *Discov. Ment. Heal.*, vol. 5, no. 1, 2025.
- [2] N. Haque, T. Islam, and M. Erfan, "An exploration of machine learning approaches for early Autism Spectrum Disorder detection," *Healthc. Anal.*, vol. 7, no. December 2023, 2025.
- [3] D. M. Setu, T. Islam, M. M. Rahman, S. K. Dey, and T. Rahman, "Evaluating the efficacy and site-specific performance of machine learning approaches: A comprehensive review of autism detection models," *Franklin Open*, vol. 11, no. May, 2025.
- [4] S. B. Siagian, S. Samsudin, and M. D. Irawan, "Implementation of Gain Ratio on KNN Method in

- Predicting Sales of Electronic Sparepart at Panasonic Service Center Lhokseumawe,” *J. Tek. Inform. C.I.T Medicom*, vol. 14, no. 1, pp. 36–47, 2022.
- [5] S. Cheekaty and G. Muneeswari, “Early detection of autism spectrum disorder in children: A review,” *AIP Conf. Proc.*, vol. 3044, no. 1, 2024.
- [6] Q. Y. Shambour, N. Qandeel, Y. Alraba’nah, A. Abumariam, and M. K. Shambour, “Artificial Intelligence Techniques for Early Autism Detection in Toddlers: A Comparative Analysis,” *J. Appl. Data Sci.*, vol. 5, no. 4, pp. 1754–1764, 2024.
- [7] K. H. Abdulkareem, Z. H. Arif, and M. A. Mohammed, “Explainable Machine Learning Approach enables Computer-Aided Identification System for Children Autism Spectrum Disorder (C-ASD),” *Iraqi J. Comput. Sci. Math.*, vol. 5, no. 4, 2024.
- [8] M. Ahmed *et al.*, “Summarizing Recent Developments on Autism Spectrum Disorder Detection and Classification Through Machine Learning and Deep Learning Techniques,” *Appl. Sci.*, vol. 15, no. 14, pp. 1–40, 2025.
- [9] N. Alam *et al.*, “A Machine Learning Framework for Early Detection of Autism Spectrum Disorder in Adults Using Feature Scaling and Classification Techniques,” *2024 27th Int. Conf. Comput. Inf. Technol. ICCIT 2024 - Proc.*, no. December, pp. 3248–3253, 2024.
- [10] H. A. Hatim, Z. A. A. Alyasseri, and N. Jamil, “A recent advances on autism spectrum disorders in diagnosing based on machine learning and deep learning,” *Artif. Intell. Rev.*, vol. 58, no. 10, 2025.
- [11] D. D. Khudhur and S. D. Khudhur, “The classification of autism spectrum disorder by machine learning methods on multiple datasets for four age groups,” *Meas. Sensors*, vol. 27, no. March, 2023.
- [12] M. Kumar, J. Aggarwal, A. Rani, T. Stephan, A. Shankar, and S. Mirjalili, “Secure video communication using firefly optimization and visual cryptography,” *Artif. Intell. Rev.*, vol. 55, no. 4, pp. 2997–3017, 2022.
- [13] N. Mumenin, M. M. Rahman, M. A. Yousuf, F. M. Noori, and M. Z. Uddin, “Early diagnosis of autism across developmental stages through scalable and interpretable ensemble model,” *Front. Artif. Intell.*, vol. 8, 2025.
- [14] P. Praveen, M. Nagendra, M. A. Rahul, Sahithya, S. Sai, and Shoaib, “Identification of Autism Spectrum Disorder (ASD) using Feature-based Machine Learning Classification Model,” *2nd Int. Conf. Sustain. Comput. Smart Syst. ICSCSS 2024 - Proc.*, vol. 17, no. 3, pp. 1378–1384, 2024.
- [15] M. D. Ganggayah *et al.*, “Accelerating autism spectrum disorder care: A rapid review of data science applications in diagnosis and intervention,” *Asian J. Psychiatr.*, vol. 108, no. April, 2025.
- [16] H. H. Hasan, “Artificial Intelligence in Early Detection of Autism Spectrum Disorder for Preschool ages: A Systematic Literature Review,” *medRxiv*, no. December 2024, p. 2025.09.10.25335333, 2025.
- [17] U. J. Ganai, A. Ratne, B. Bhushan, and K. S. Venkatesh, “Early detection of autism spectrum disorder: gait deviations and machine learning,” *Sci. Rep.*, vol. 15, no. 1, pp. 1–19, 2025.
- [18] S. N. Safitri, H. Setiadi, and E. Suryani, “Educational Data Mining Using Cluster Analysis Methods and Decision Trees based on Log Mining,” *J. RESTI*, vol. 6, no. 3, pp. 448–456, 2022.
- [19] R. Simeoli, A. Rega, M. Cerasuolo, R. Nappo, and D. Marocco, “Using Machine Learning for Motion Analysis to Early Detect Autism Spectrum Disorder: A Systematic Review,” *Rev. J. Autism Dev. Disord.*, no. 0123456789, 2024.
- [20] E. S. Atlam, K. O. Aljuhani, I. Gad, E. M. Abdelrahim, A. E. M. Atwa, and A. Ahmed, “Automated identification of autism spectrum disorder from facial images using explainable deep learning models,” *Sci. Rep.*, vol. 15, no. 1, p. 41598, 2025.
- [21] G. A. Pradipta and Putu Desiana Wulaning Ayu, “Performansi Seleksi Fitur pada Metode Multi Klasifikasi untuk Deteksi Dini Autisme Berbasis Citra Wajah Anak,” *J. Sist. dan Inform.*, vol. 18, no. 2, pp. 167–176, 2024.
- [22] L. Hakim, A. Sobri, L. Sunardi, and D. Nurdiansyah, “Prediksi penyakit jantung berbasis mesin learning dengan menggunakan metode k-nn,” *J. Digit. Teknol. Inf.*, vol. 7, no. 2, p. 14, 2025.
- [23] R. Ayub, S. Immamul Ansarullah, F. Samdani, A. Akhtar, M. Afzal, and S. Moinuddin Ahmed, “Enhancing early detection of autistic spectrum disorder in children using machine learning approaches,” *J. King Saud Univ. - Sci.*, vol. 36, no. 10, 2024.
- [24] I. Jeon *et al.*, “Reliable Autism Spectrum Disorder Diagnosis for Pediatrics Using Machine Learning and Explainable AI,” *Diagnostics*, vol. 14, no. 22, 2024.
- [25] P. Bawa, V. Kadyan, A. Mantri, and H. Vardhan, “Investigating multiclass autism spectrum disorder classification using machine learning techniques,” *e-Prime - Adv. Electr. Eng. Electron. Energy*, vol. 8, no. May, p. 100602, 2024.