



## Diagnosa Awal Autisme pada Anak dengan *Algoritma Machine Learning*

*Early Autism Diagnosis in Children Using Machine Learning Techniques*

Taryadi<sup>1\*</sup>, Era Yunianto<sup>2</sup>, Mosses Aidjili<sup>3</sup>

<sup>1,2</sup>Sistem Informasi, Fakultas Teknologi Informasi, Institut Widya Pratama, Pekalongan, Indonesia

<sup>3</sup>Teknik Informatika, Fakultas Teknologi Informasi, Institut Widya Pratama, Pekalongan, Indonesia

<sup>1</sup>tari\_ball@stmik-wp.ac.id, <sup>2</sup>era.yunianto@gmail.com, <sup>3</sup>mossesaaidjili@gmail.com

### Abstract

Neurological ailments known as autism spectrum disorder is typified by repetitive activities, social isolation, and poor communication abilities. Developing an efficient ASD diagnosis system that enables accurate analysis and early autism prediction is a challenge for international health organizations. By using important characteristics and machine learning techniques, this study offers a strategy for early detection of children with ASD. Five variables—gender, delayed speech, jaundice, genetic diseases, and family history—are used to calculate the Pearson correlation coefficient in the dataset, which includes 1250 instances with ASD. Five Machine Learning approaches are used in dataset analysis: AdaBoostM1, Naïve Bayes, K-Nearest Neighbor, Decision Tree, and Support Vector Machine. The ML method is tested using metrics such as accuracy, precision, prediction time, recall, and F1-score. According to the test findings, the Naïve Bayes and K-Nearest Neighbor algorithms had minimal prediction times of 0.31 and 0.46 seconds and accuracy rates of 99.2% and 96.3%, respectively. In the meantime, Decision Tree and AdaBoostM1 exhibit declining accuracy, with 95.8% and 88.6%, respectively. With an accuracy rate of 81.2% and a maximum prediction time of 0.82 seconds, the Support Vector Machine approach performs the worst.

**Keywords:** ASD; autistic diagnosis; healthcare engineering; machine learning; prediction

### Abstrak

Gangguan spektrum autisme adalah kondisi neurologis yang ditandai dengan gangguan kemampuan komunikasi, keterasingan sosial, dan perilaku repetitif pada individu. Organisasi kesehatan global menghadapi kesulitan dalam membangun sistem diagnostik ASD yang efektif yang memfasilitasi analisis yang tepat dan prediksi autisme dini. Penelitian ini menyajikan pendekatan untuk prediksi dini anak-anak dengan ASD dengan memanfaatkan variabel signifikan melalui metode pembelajaran mesin. Data set terdiri dari kasus ASD sebanyak 1250 data dimana diambil 5 variabel yang sangat efektif untuk menghitung koefisien korelasi pearson yaitu: jenis kelamin, keterlambatan bisaca, penyakit kuning, gangguan genetik dan riwayat keluarga. Analisis dataset menggunakan lima teknik *Machine Learning* yaitu: Naïve Bayes, K-Nearest Neighbor, Decision Tree, Support Vector Machine dan AdaBoostM1. Pengukuran akurasi, presisi, waktu prediksi, recall dan F1-score digunakan untuk menguji algoritma ML yang digunakan. Hasil pengujian menunjukkan bahwa metode Naïve Bayes dan K-Nearest Neighbor dengan tingkat akurasi sebesar 99,2% dan 96,3% dan waktu prediksi yang minimal sebesar 0,31 dan 0,46 detik. Sedangkan metode yang menunjukkan penurunan akurasi adalah Decision Tree dan AdaBoostM1 dengan masing-masing sebesar 95,8% dan 88,6%. Sedangkan kinerja paling rendah adalah metode Support Vector Machine dengan tingkat akurasi sebesar 81,2% dan waktu prediksi tertinggi sebesar 0,82 detik.

Kata kunci: gangguan spektrum autis; rekayasa kesehatan; pembelajaran mesin; prediksi

### 1. Pendahuluan

Sebuah kondisi perkembangan saraf, gangguan spektrum autisme (ASD) memengaruhi sekitar 24,8 juta orang di seluruh dunia. Minat dan perilaku yang sangat repetitif menyertai ciri-ciri gangguan komunikasi dan interaksi sosial [1]. Anak-anak kecil dengan ASD dapat mengalami gangguan fungsional

yang cukup besar. Oleh karena itu, diagnosis dini dan tepat sangat penting untuk meningkatkan kualitas hidup, tingkat keparahan gejala, dan perilaku maladaptif. Meskipun banyak penelitian, proses neurologis ASD masih belum jelas. Oleh karena itu, ASD didiagnosis berdasarkan perilaku, bukan penyebab atau mekanisme [2]. Setelah ASD didiagnosis, pengujian genetik secara rutin digunakan

untuk mengungkap faktor keturunan, namun hal tersebut hanya menunjukkan risiko. Akan tetapi, penelitian telah mengalami kemajuan yang signifikan [3].

Deteksi dini ASD pada anak-anak tetap menjadi tantangan yang signifikan karena keterbatasan infrastruktur teknologi, implementasi alat skrining yang tidak memadai, dan kurangnya kerangka kerja sistemik untuk pengawasan perkembangan. Pendekatan tradisional terbukti tidak cukup untuk memenuhi permintaan yang meningkat untuk diagnosis dan intervensi yang tepat waktu, sehingga memengaruhi lintasan perkembangan anak-anak yang terkena dampak [4]. Kendala-kendala ini diperparah oleh kurangnya kesadaran umum di antara pengasuh dan profesional perawatan kesehatan, integrasi teknologi diagnostik yang terbatas, dan tidak adanya mekanisme strategis utama untuk meningkatkan kemanjuran deteksi. Akibatnya, tingkat diagnosis ASD yang tertunda yang tinggi, dengan disparitas regional yang substansial. Bukti empiris menunjukkan bahwa sebagian besar anak-anak tidak didiagnosis dengan autisme sampai mencapai usia sekolah atau lebih, sehingga kehilangan jendela penting untuk intervensi dini. Selain itu, ketersediaan data nasional yang andal dan terstandarisasi tentang prevalensi autisme, tingkat skrining, dan hasil diagnostik masih terbatas. Menurut laporan tahun 2021 oleh Organisasi Kesehatan Dunia (WHO), anak-anak yang tinggal di daerah kurang terlayani yang tidak memiliki layanan pediatrik atau *neurodevelopment* khusus berisiko lebih tinggi mengalami keterlambatan diagnosis dan hasil perawatan yang kurang optimal [5].

Dari sudut pandang teknik, sistem perawatan kesehatan menghadapi berbagai tantangan teknologi dan infrastruktur. Ada kekurangan yang meluas dari catatan kesehatan elektronik, aplikasi skrining seluler, dan alat penilaian perkembangan berbasis AI. Selain itu, pengasuh dan dokter sering kali tidak memiliki pelatihan teknis yang diperlukan untuk memanfaatkan sistem tersebut secara efektif. Sumber daya keuangan yang terbatas semakin menghambat perolehan *platform* diagnostik canggih atau penggunaan profesional terlatih dalam pediatrik perkembangan dan perilaku. Di wilayah-wilayah di mana sistem lama (yaitu, catatan berbasis kertas atau penilaian non-standar) masih digunakan, resistensi untuk mengintegrasikan sistem *modern* seperti *platform* skrining ASD yang mendukung *telehealth* atau alat pengenalan perilaku ML tetap ada.

Secara tradisional, anak-anak dengan ASD diprediksi dengan menganalisis perilaku sekitar usia 18–36 bulan. Namun, menunda intervensi pada tahap penting komunikasi sosial dan pembelajaran pada anak-anak yang terkena dampak dapat mengurangi efektivitasnya. Teknologi otomatis yang merekam video dan suara anak dari interaksi publik dan menggunakan analisis pembelajaran mesin untuk mendeteksi dan

mengantisipasi anak-anak dengan ASD berisiko tinggi akan membuat penilaian risiko dan intervensi dini lebih mudah diakses [5-6]. Dengan demikian, kumpulan data ASD yang telah diproses sebelumnya dan seimbang dapat membantu penelitian autisme. Tahap-tahap praproses dapat dianggap benar dan berhasil memberikan hasil yang lebih baik daripada kumpulan data ASD asli [7].

Jaber et al. [8] pada tahun 2020 melakukan penelitian dengan metode Klasifikasi Asosiasi untuk memprediksi keberadaan autisme pada individu. Untuk mengidentifikasi korelasi di antara data, tujuh algoritma dipilih untuk menganalisis dan mengevaluasi kinerja metode klasifikasi asosiasi. *Dataset* tidak seimbang dengan 21 karakteristik. Kaushik et al. [9] pada tahun 2021 mengembangkan model prediksi berdasarkan hasil dengan menggunakan algoritma pembelajaran mesin, seperti *Support Vector Machines* (SVM), *Random Forest Classifier* (RFC), *Naïve Bayes* (NB), *Logistic Regression* (LR), dan *K-Nearest Neighbors* (KNN). Jumlah *dataset* ASD yang luas dan sumber yang terbuka sangat terbatas, yang merupakan kendala utama penelitian ini. Untuk membangun model yang akurat, *dataset* yang signifikan sangat penting. *Dataset* yang digunakan tidak memiliki jumlah kasus yang cukup.

Amandeep dan Karanjeet [10] menggunakan enam algoritma pembelajaran mesin untuk klasifikasi, termasuk C4.5, *k-Nearest Neighbors*, *Random Forest*, *Logit Boost*, *Support Vector Machine*, dan *Naive Bayes*. Data aktivitas waktu nyata digunakan untuk menentukan ADHD pada orang dewasa. Salah satu kendala utamanya adalah kelangkaan sampel data, yang merupakan hasil dari masalah dalam pengumpulan data klinis. Moushumi et al. menggunakan berbagai pengklasifikasi dalam data balita, anak-anak, remaja, dan dewasa [11]. Garis dasar dan kumpulan fitur yang lebih efisien juga didukung melalui penggunaan berbagai teknik pemilihan fitur. Model ini mempelajari fitur penting tetapi tidak dilatih menggunakan kumpulan data multivariat atau multidimensi.

Penelitian terbaru menggarisbawahi konsekuensi dari kurangnya pemanfaatan teknologi dalam deteksi dini ASD. Penelitian ini menekankan perlunya solusi interdisipliner yang menggabungkan inovasi rekayasa dengan strategi kesehatan masyarakat [2, 12]. Misalnya, dengan demikian menawarkan data yang penting untuk model rekayasa yang ditujukan pada sistem prediksi ASD otomatis yang dapat diskalakan. Berikut ini adalah beberapa pendekatan paling inovatif untuk diagnosis ASD [13]

Penelitian diagnosis dan prediksi ASD telah menunjukkan banyak keterbatasan dan tantangan substansial. Salah satu masalahnya adalah bahwa ukuran sampel homogen yang kecil mengurangi generalisasi hasil ke populasi lain. Penilaian subjektif



seperti observasi klinis dan laporan orang tua digunakan dalam banyak penelitian, yang dapat mendistorsi hasil [4]. Karena model tertentu kurang dapat ditafsirkan dan tahan lama, penggunaan pendekatan pembelajaran mesin tingkat lanjut yang terbatas menjadi masalah lain. Fokus pada fitur yang berbeda daripada faktor biologis, lingkungan, dan perilaku juga menyebabkan pemahaman yang terbatas. Masalah ini harus ditangani untuk meningkatkan diagnosis dan prediksi ASD [14]. Diagnosis ASD memerlukan penilaian klinis dan tes standar untuk memastikan diagnosis yang tepat dan perawatan yang tepat. Dalam perawatan kesehatan anak, autisme merupakan kendala utama. Identifikasi ASD sangat penting untuk intervensi dini yang dapat memengaruhi perkembangan.

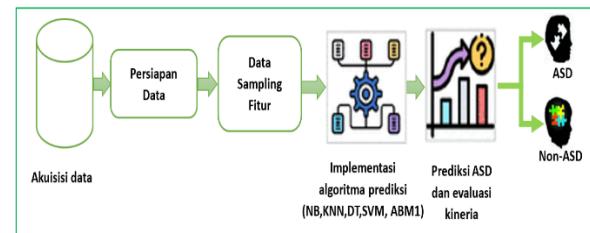
Ada sejumlah cara untuk menentukan korelasi antara atribut dalam kumpulan data guna memahami saling ketergantungan dan hubungan diantara atribut tersebut dalam kerangka analisis fitur untuk ML. Tingkatkan kinerja model dengan menggabungkan fitur sesuai dengan korelasinya. Di antara metode yang paling efektif adalah *Pearson Coeffisience Correlation* (PCC) yang mengukur hubungan linier antara dua variabel kontinu. PCC banyak digunakan dalam statistik, penelitian, dan analisis data untuk memahami hubungan antara variabel [15]. Memberikan kemampuan untuk menghapus fitur yang berlebihan (fitur sangat berkorelasi), mempertimbangkan untuk menghapus satu fitur guna mengurangi multikolinearitas serta memilih fitur yang relevan dengan memilih fitur yang memiliki korelasi kuat dengan variabel target (variabel dependen) dan korelasi yang lebih rendah satu sama lain [16]. Studi ini tidak hanya memfasilitasi identifikasi keterlambatan yang dipersonalisasi dalam fungsi atau struktur otak yang terkait dengan ASD, tetapi juga menggambarkan kemanjuran data relevan dalam menjelaskan hubungan di antara fitur-fitur mengenai dampaknya pada kinerja model untuk model prediktif indikator ASD awal dalam sampel data fisiologis, yang telah menjadi penekanan upaya prediksi ASD melalui pemanfaatan metode PCC dengan berbagai atribut untuk meningkatkan pengukuran presisi [17].

## 2. Metode Penelitian

Tujuan utama penelitian ini adalah untuk memprediksi probabilitas ASD pada tahap awal dan untuk lebih jauh menggambarkan atribut yang berkontribusi lebih signifikan daripada yang lain terhadap prediksi presisi yang ditingkatkan. Hal ini dapat mengurangi biaya yang terkait dengan beberapa uji coba pasien, karena tidak semua karakteristik dapat secara signifikan memengaruhi prediksi hasil [18].

Berdasarkan kumpulan data, kerangka kerja yang disarankan untuk prediksi awal ASD di antara kontrol klinis disajikan pada Gambar 1 dan oleh karena itu membantu untuk prediksi awal apakah seorang anak

akan atau tidak memperoleh ASD. Data pertama kali diperoleh dari situs Kaggle [19], yang terdiri dari informasi pasien termasuk latar belakang faktor risiko sosiodemografi dan riwayat keluarga.



Gambar 1. Kerangka kerja yang diusulkan

Teknik PCC diimplementasikan untuk menemukan korelasi di antara sepuluh fitur. Lima fitur berbeda diekstraksi dengan nilai korelasi positif tertinggi dan kemudian dimasukkan ke dalam lima algoritma ML yang berbeda (NB, k-NN, DT, SVM, dan ABM1) untuk proses lebih lanjut.

### 2.1. Akuisisi dan Praproses Data

Selama prosedur partisi data, kumpulan data yang mencakup 1250 instans disegmentasikan menjadi dua segmen untuk analisis lebih lanjut. 80% data ditujukan untuk pelatihan, sedangkan 20% sisanya dicadangkan untuk pengujian. Data di kolom pertama Tabel 1, yang berkaitan dengan jenis kelamin, dikodekan sebagai nol untuk perempuan dan satu untuk laki-laki. Frasa "ya" dan "tidak" masing-masing diberi nilai satu dan nol, di seluruh pengumpulan data.

Tabel 1. Contoh dataset yang diimplementasikan

#	JK	K B	K Bl	M S	Dp	G K K	P K G	K G	S K	ASD
1	0	1	1	1	1	1 1 1	1 1 1	1 1 1	0	1
2	1	1	0	0	1	1 1 1	1 1 1	1 1 1	1	1
3	1	1	1	1	1	1 1 1	1 1 1	1 1 1	0	1
4	1	1	1	1	1	1 0 0	1 0 0	0 0 0	0	1
5	0	1	1	1	1	1 0 0	1 0 0	0 0 0	0	0
6	1	1	1	1	1	1 0 0	0 0 0	0 0 0	0	1

Keterangan : JK: Jenis Kelamin, KB: Keterlambatan Bicara; KB1: Keterbasan belajar; MS: Masalah sosial; Dp: Depresi; GK: Gangguan kecemasan; PK: Penyakit kuning; KG: Kelainan genetik; SK: Sejarah keluarga.

### 2.2. Pemilihan Fitur

Pemilihan fitur meningkatkan kinerja dan efisiensi dan merupakan langkah penting dalam perkembangan sistem prediksi. Dengan menghilangkan elemen yang tidak penting atau duplikat, pemilihan fitur mengurangi dimensionalitas kumpulan data, yang memungkinkan waktu pelatihan dan inferensi yang lebih singkat. Pemilihan fitur juga dapat meningkatkan interpretabilitas model, memudahkan pemahaman hubungan yang diprediksi fitur. Untuk mengevaluasi korelasi antar atribut sambil mempertahankan integritas kumpulan data, teknik seperti PCC sering digunakan. Pada akhirnya, algoritma *Machine Learning* dapat berkonsentrasi pada data yang paling penting berkat pengurangan fitur yang efektif. Dalam penelitian ini, pendekatan PCC digunakan sebagai



salah satu dari sepuluh karakteristik yang mungkin terlibat: jenis kelamin, keterlambatan bicara, disabilitas intelektual, gangguan belajar, masalah sosial, depresi, gangguan kecemasan, penyakit kuning, kelainan genetik, dan riwayat keluarga.

PCC, yang sering dilambangkan sebagai ( $r$ ), mengukur kekuatan dan arah hubungan linier antara dua variabel kontinu. Nilai ini berkisar dari [-1 hingga +1]: begini cara kerjanya [20].

$$r(X, Y) = \frac{\sum_{n=1}^N (X_n - \bar{X})(Y_n - \bar{Y})}{\sqrt{\sum_{n=1}^N (X_n - \bar{X})^2} \sqrt{\sum_{n=1}^N (Y_n - \bar{Y})^2}} \quad (1)$$

Di mana  $N$  adalah jumlah sampel,  $X$  dan  $Y$  adalah dua fitur yang dibandingkan, dan  $\bar{X}$  dan  $\bar{Y}$  masing-masing mewakili rata-rata fitur tertentu. Dengan menghitung koefisien korelasi Pearson ( $r$ ) antara setiap pasangan fitur dalam kumpulan data:

$r = 1$ : Korelasi positif sempurna

$r = -1$ : Korelasi negatif sempurna

$r = 0$ : Tidak ada korelasi

Matriks korelasi dibuat untuk menampilkan koefisien korelasi pasangan fitur. Korelasi yang kuat dapat dilihat dan diidentifikasi dengan lebih baik dengan bantuan matriks ini. Tabel 2 menampilkan hubungan di antara 10 fitur yang diimplementasikan.

Tabel 2. Matriks korelasi untuk kumpulan data dengan sepuluh fitur

	JK	K B	K Bl	M S	Dp	G K	PK	KL	SK
JK	1	0.2 26	0.2 30	0.2 28	0.2 28	0.2 27	- 0.0 46	0.20 4	0.0 59
KB	0.22 68	1 60	0.9 91	1 63	1 51	0.9 45	- 0.0 6	0.89 1	0.2 36
KBI	0.23 0919	0.9 60	1 60	0.9 63	0.9 51	0.9 27	- 0.0 45	0.85 6	0.2 30
MS	0.22 8	1 60	0.9 93	1 91	0.9 49	0.9 49	- 0.0 1	0.89 36	0.2 5
Dp	0.22 82	1 63	0.9 93	1 94	0.9 9	0.9 77	- 0.0 114	0.89 39	0.2 4
GK	0.22 764	0.9 91	0.9 51	0.9 91	0.9 90	1 49	- 0.0 287	0.88 27	0.2 9
PK	- 0.04 63	- 0.0 48	- 0.0 45	- 0.0 49	- 0.0 48	- 0.0 49	1 236	0.01 33	0.1 4
KG	0.20 46	0.8 91	0.8 56	0.8 91	0.8 91	0.8 82	0.0 12 36	1 16 7	0.2 16 7
SKa	0.05 9	0.2 36	0.2 30	0.2 36	0.2 39	0.2 27	0.1 33 4	0.21 67	1

Terdapat nilai korelasi positif yang signifikan antara (keterlambatan bicara, gangguan belajar, disabilitas intelektual, masalah sosial, depresi, dan gangguan kecemasan) sekitar (0,981). sedangkan, 'Penyakit kuning' memiliki korelasi negatif tertinggi sekitar (-0,05) yang menunjukkan hubungan terbalik dengan kesembilan fitur tersebut. Memahami hubungan ini sangat penting untuk konseling genetik, penilaian risiko, dan intervensi dini dalam keluarga dengan riwayat ASD atau kondisi terkait.

Singkatnya, pemilihan pendekatan korelasi yang tepat ditentukan oleh jenis kumpulan data yang digunakan dan asumsi distribusi yang digunakan. Setiap teknik memiliki kelebihannya sendiri dan sesuai untuk berbagai jenis analisis.

### 2.3. Prediksi

Studi ini menggunakan beberapa metode ML yang diawasi. Algoritma fundamental sebagian besar dilatih menggunakan kumpulan data berlabel. Model kualifikasi mengkategorikan kumpulan data pengujian yang tidak berlabel ke dalam kategori yang sesuai. Subbagian berikutnya memberikan rekomendasi teknik ML terbimbing untuk deteksi penyakit [9].

#### 2.3.1. Naïve Bayes (NB)

NB adalah teknik klasifikasi yang mudah dan efektif yang didasarkan pada teorema Bayes, yang mengandaikan independensi fitur. Metode ini menghitung probabilitas setiap kelas berdasarkan karakteristik dan menetapkan label dengan kemungkinan terbesar. Meskipun metode ini bekerja sangat baik dengan kumpulan data kecil dan memiliki kecepatan komputasi yang cepat, efektivitasnya dapat berkurang ketika karakteristik menunjukkan korelasi yang signifikan. *Naïve Bayes* terus menjadi pilihan yang disukai karena kesederhanaan dan efektivitasnya.

#### 2.3.2. K-Nearest Neighbor (K-NN)

K-NN adalah salah satu algoritma klasifikasi yang paling sederhana.  $K$  adalah jumlah tetangga terdekat, yang dapat diberikan dalam konstruktur objek atau dihitung menggunakan batas atas nilai [21]. Dengan demikian, contoh analog digolongkan secara serupa, dan kasus baru digolongkan dengan membandingkannya dengan masing-masing contoh. Setelah menerima sampel yang tidak teridentifikasi, algoritma *nearest neighbor* akan mencari ruang pola untuk  $k$  sampel pelatihan di sebelahnya. Jarak dari contoh pengujian dapat digunakan untuk menghitung prediksi dari banyak tetangga, dan dua metode ditunjukkan untuk memberi bobot pada jarak tersebut.

#### 2.3.3. Decision Tree (DT)

DT adalah algoritma ML yang serbaguna dan intuitif yang digunakan untuk tugas klasifikasi dan regresi. Algoritma ini bekerja dengan membagi data menjadi beberapa bagian berdasarkan nilai fitur, menciptakan struktur keputusan dan hasil seperti pohon. Setiap



simpul perantara mewakili pengujian pada suatu fitur, cabang sesuai dengan kemungkinan hasil, dan simpul daun memberikan prediksi akhir [22]. DT mudah ditafsirkan dan menangani data numerik dan kategoris secara efektif. Model DT melakukan analisis berdasarkan tiga node:

- Node dasar: node utama, yang berdasarkan node lainnya berfungsi.
- Node perantara: menangani berbagai atribut.
- Node daun: mewakili hasil dari setiap pengujian.

#### 2.3.4. Support Vector Machine (SVM)

Pendekatan ML yang diawasi, SVM digunakan untuk aplikasi prediksi, regresi, dan klasifikasi. memiliki tingkat efisiensi yang tinggi dalam ruang berdimensi tinggi dan tahan terhadap *overfitting*, terutama dalam situasi ketika jumlah fitur lebih besar daripada jumlah sampel. Sebagai hasil dari fungsi keputusan yang hanya menggunakan sebagian dari data pelatihan, SVM menjadi efisien [23].

#### 2.3.5. AdaboostM1 (ABM1)

Pengklasifikasi ML terbimbing berbasis pembelajaran ensemble ABM1. Pengklasifikasi ini menggunakan peningkatan adaptif untuk menggabungkan banyak pengklasifikasi lemah menjadi pengklasifikasi tangguh untuk hasil klasifikasi yang lebih baik. Fase pendahuluan memberi bobot yang sama pada semua observasi. Koefisien pengklasifikasi lemah memengaruhi bobot observasi, sedangkan nilai galat estimasi menentukan koefisien pengklasifikasi. Koefisien pengklasifikasi adalah nilai galatnya [24]. Dengan demikian, algoritme ABM1 dapat memberi bobot yang lebih tinggi pada data yang salah klasifikasi dan lebih rendah pada data yang terkenal. Pada putaran berikutnya, algoritme ini akan menekankan observasi yang salah klasifikasi. Dengan menggunakan kombinasi linier, semua pengklasifikasi lemah digabungkan untuk membangun pengklasifikasi yang lebih tangguh yang menghasilkan hasil klasifikasi yang akurat. Kumpulan data ASD dilatih dan dievaluasi menggunakan pendekatan ini. Pustaka Kaggle menjalankan algoritme prediksi.

#### 2.4. Metrik Evaluasi dan Analisis Kinerja

Lima algoritma prediktif digunakan pada kumpulan data seimbang analog yang mencakup 1250 contoh untuk mengidentifikasi metode yang paling efektif dengan membandingkan akurasi dan metrik statistik lainnya. Algoritma yang digunakan adalah (NB, KNN, DT, SVM, dan ABM1). Artikel ini memberikan gambaran singkat tentang tinjauan kinerja. Tabel 3 mengilustrasikan matriks kebingungan dari studi yang diusulkan untuk menilai kinerja setiap metode yang digunakan.

Tabel 3. Confusion Matrik Prediksi ASD

	Anak dengan ASD	Anak tanpa ASD
Prediksi ASD	TP	FP
Bukan prediksi ASD	TN	FN

Keterangan: TP (True Positive); TN (True Negative); FP (False Positif); FN (False Negative)

Tabel 4. Perbandingan Metrik Evaluasi Untuk Algoritma Yang Diujii

	NB	K-NN	DT	SVM	ABM1
Akurasi	98,8	96,4	93,6	74,4	86,8
F1-Score	98,7	96,3	93,7	77,4	91,3
Recall	99,1	97,5	91,6	69,1	86,4
Presisi	98,4	95,2	96	88	96,8
Confusion Matrix	[123] [2] [1] 124	[119] [6] [3] [124]	[120] [2] [11] [114]	[110] [2] [49] [124]	[121] [4] [19] [124]

Presisi, *recall*, dan *f-score* memperkirakan kesepakatan antar penilai dari akurasi yang diidentifikasi dan diprediksi untuk variabel kualitatif digunakan untuk menilai efisiensi algoritma. Presisi merupakan indikator penilaian yang baik ketika model ML yang diusulkan harus divalidasi menggunakan hasil yang diharapkan dan aktual. Presisi memperkirakan rasio positif-ke-positif aktual yang diprediksi. Hal ini membuatnya bergantung pada TP dan FP [12].

$$\text{Presisi} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

*Recall*, yang menunjukkan persentase positif yang diklasifikasikan dengan benar, merupakan statistik penilaian lain yang berguna untuk digunakan ketika mencoba memperkirakan berapa banyak positif yang dapat diharapkan secara wajar. Nilai TP dan FN digunakan untuk mengukur *recall*.

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3)$$

*F-Score* menyeimbangkan akurasi dan recall untuk suatu pengklasifikasi. Skor *F-Score* adalah nilai yang berkisar dari 0 hingga 1 yang menandakan metrik akurasi dan *recall* yang relevan secara statistik.

$$F - \text{Score} = \frac{2 * \text{Recall} * \text{Precision}}{\text{Recall} + \text{Precision}} \quad (4)$$

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}} \times 100\% \quad (5)$$

dimana,

- 1) Positif benar (TP): Individu tersebut memiliki ASD dan diprediksi dengan benar.
- 2) Negatif benar (TN): Individu tersebut tidak memiliki ASD dan diprediksi dengan benar.
- 3) Positif salah (FP): Individu tersebut tidak memiliki ASD, tetapi diprediksi secara salah bahwa individu tersebut memiliki ASD. Ini dikenal sebagai kesalahan Tipe 1.

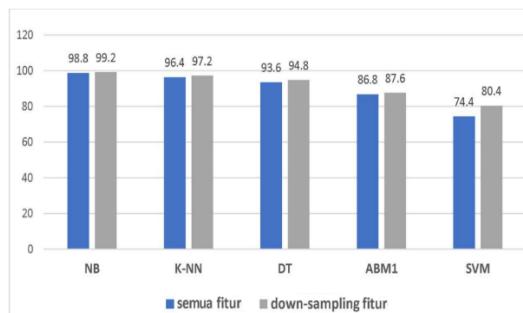


Negatif salah (FN): Individu tersebut memiliki ASD, tetapi diprediksi secara salah bahwa individu tersebut tidak memiliki ASD. Ini dikenal sebagai kesalahan Tipe 2.

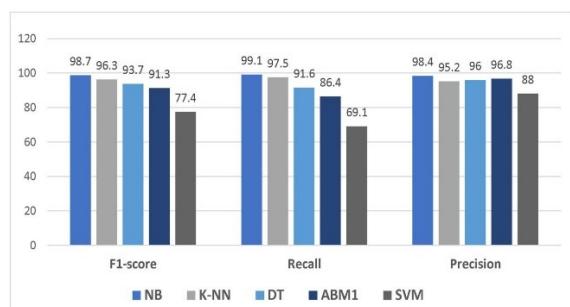
### 3. Hasil dan Pembahasan

Rincian evaluasi dari lima algoritma yang diterapkan melalui 1250 kasus untuk sepuluh fitur dan setelah menerapkan PCC untuk menyunting fitur menjadi lima fitur berbeda (jenis kelamin, keterlambatan bicara, penyakit kuning, kelainan genetik, dan riwayat keluarga) diperkenalkan masing-masing dalam Tabel (3 dan 4).

Analisis kedua tabel tersebut mengungkap pengamatan yang signifikan: mengurangi fitur menjadi setengahnya, berdasarkan metode yang diterapkan, telah menunjukkan peningkatan substansial di berbagai metrik yang dipertimbangkan dalam penelitian. Hal ini menunjukkan bahwa pemilihan fitur memainkan peran penting dalam meningkatkan kinerja model prediktif dengan menghilangkan fitur yang berlebihan atau tidak relevan. Dengan berfokus pada atribut yang paling informatif, model tersebut tidak hanya mencapai akurasi dan efisiensi yang lebih tinggi tetapi juga mengurangi kompleksitas komputasi. Peningkatan ini menggarisbawahi pentingnya mengadopsi teknik fitur down-sampling yang kuat untuk mengoptimalkan algoritma ML demi kinerja dan keandalan yang lebih baik. Gambar 2 mengilustrasikan akurasi prediksi dari lima algoritma yang diterapkan untuk semua sepuluh fitur versus menggunakan kumpulan data fitur down-sampling.



Gambar 2. Akurasi Prediksi

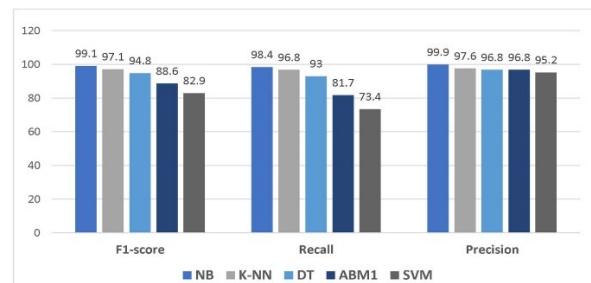


Gambar 3 Metrik kinerja menggunakan sepuluh fitur

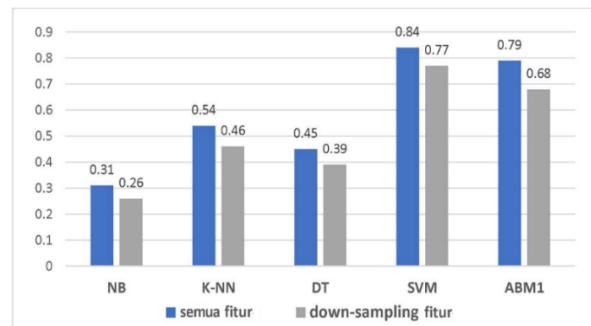
Dalam kedua skenario, NB mengungguli semua pengklasifikasi lainnya dengan akurasi 98,8%, 99,9%. Akurasi terendah 74,4%, 80,4% oleh algoritma SVM.

Skor F1, recall, presisi, dan spesifitas sepuluh fitur serta fitur down-sampling digunakan untuk mengevaluasi signifikansi hasil seperti yang ditunjukkan pada Gambar (3 dan 4).

Dalam konteks algoritma klasifikasi, satuan waktu dapat merujuk pada cara mengukur upaya komputasi yang diperlukan untuk melatih dan menjalankan algoritma ini. Waktu untuk algoritma ML yang berbeda sangat bervariasi tergantung pada beberapa faktor seperti: ukuran kumpulan data, kompleksitas model, dan sumber daya komputasi yang tersedia. Dalam bidang ini, dan untuk menentukan efisiensi algoritma yang diterapkan, waktu rata-rata yang diperlukan untuk memprediksi hasil setiap kasus data yang digunakan untuk tujuan pengujian dan untuk setiap algoritma telah dihitung. Waktu inferensi atau prediksi adalah waktu yang dibutuhkan model untuk memprediksi atau menyimpulkan output untuk data baru. Total waktu yang dibutuhkan untuk memproses dataset ASD untuk setiap algoritma yang diterapkan diilustrasikan pada Gambar 4.



Gambar 4. Metrik kinerja menggunakan fitur down-sampling



Gambar 5. Waktu yang diperlukan untuk memprediksi kondisi pasien untuk algoritma yang digunakan

Waktu prediksi minimum algoritma NB dengan 0,26 detik, sementara itu meningkat drastis menjadi 0,46 detik dengan algoritma k-NN. Namun, waktu tersebut sedikit menurun menjadi 0,39 detik dengan algoritma DT, yang merupakan sekitar setengah dari waktu yang tercatat dari algoritma SVM serta ABM1.

Hasil perbandingan dengan karya lain menunjukkan bahwa akurasi yang lebih baik serta waktu prediksi dapat dicapai dengan menggunakan teknik yang diusulkan dengan fitur down-sampling. Jumlah fitur yang dikurangi juga membuat pengujian tidak terlalu lambat. Jadi, algoritma ML dengan teknik pengurangan fitur membuat prediksi ASD tidak



memakan banyak waktu bersama dengan akurasi yang lebih baik dan kinerja keseluruhan. Perbandingan teknik yang diusulkan dengan karya seni terkini disajikan dalam Tabel 6.

Tabel 5. Perbandingan Metrik Evaluasi Untuk Algoritma Yang Diuji

	NB	K-NN	DT	SVM	ABM1
Akurasi	99,2	97,2	94,8	87,6	80,4
F1-Score	99,1	97,1	94,8	88,6	82,9
Recall	98,4	96,8	93	81,7	73,4
Precision	99,9	97,6	96,8	96,8	95,2
Confusion Matrix	125 0 2	122 3 123	121 4 116	121 4 27 98	119 6 43 82

Tabel 6. Perbandingan Model Yang Diusulkan Dengan Pelitian Sebelumnya

	Data set	Akurasi (%)	Keterbasan	Kekuatan
[9]	292 record	CNN:9 5,1 NN:92, 3 LR:95, 08 SVM:9 5,3 NB:97, 53	tidak memprediksi tingkat keparahan ASD dalam kasus tertentu, gejala yang digunakan untuk mendiagnosis ASD mungkin tidak selalu menunjukkan kejadian sebenarnya dari gangguan tersebut	memperoleh presisi tinggi dengan memanfaatkan lima teknik kategorisasi berbasis ML yang berbeda
[25]	1054 record; 18 Atribut	LR: 92,8 RF: 82,6 SVM: 94,1 NB: 95,2 KNN: 91,6	sebagai konsekuensi dari fakta bahwa kumpulan data sebagian besar dikumpulkan dari koleksi berbasis autisme, terdapat ketidakseimbangan yang cukup besar, terutama yang menguntungkan kelas ASD.	pemilihan fitur maju digunakan, dan lima model pembelajaran mesin dikembangkan dan dinilai
Mod el yang diusulkan	1250 record; 5 Atribut	NB: 98,1 KNN: 96,3 DT: 95,8 SVM: 81,2 ABM1: 88,6	ASD memiliki manifestasi yang berbeda pada setiap individu, sehingga sulit untuk membuat model yang cocok untuk semua orang. Oleh karena itu, validasi model yang ketat dengan populasi yang beragam sangatlah penting.	Dataset seimbang dari 1250 anak telah diproses untuk prediksi ASD. Terapkan teknik fitur down-sampling PCC

Berdasarkan pembahasan tersebut terlihat bahwa hubungan antara jumlah fitur yang terlibat dan akurasi prediksi bergantung pada sifat kumpulan data dan kualitas fitur.

#### 4. Kesimpulan

Pentingnya teknik pembelajaran mesin dapat digunakan untuk memprediksi kemunculan penyakit karena teknik tersebut memiliki kapasitas untuk memprediksi tingkat penyakit secara akurat. Dalam penelitian ini, efisiensi metode ML diuji untuk prediksi menggunakan kumpulan data ASD seimbang

berlabel 1250 rekaman. Selain itu, kebutuhan untuk memilih atribut yang tepat untuk mendapatkan prediksi yang akurat dinilai untuk semua algoritma yang diimplementasikan. Di antara beberapa algoritma yang diterima dengan baik, mudah dibuat, cepat, dan berkinerja baik, penelitian ini mencari pendekatan ML yang paling efisien.

Hasil eksperimen menunjukkan bahwa, algoritma NB menghasilkan kinerja yang lebih unggul dibandingkan dengan empat algoritma lainnya dalam hal akurasi 99,2% dengan waktu minimum sedangkan, SVM mencapai akurasi terendah 80,4% dengan waktu maksimum karena ketika bekerja dengan kumpulan data besar, implementasi SVM memerlukan waktu pelatihan yang lama. Selain itu, hasilnya secara luar biasa menunjukkan bahwa dengan menggunakan teknik reduksi fitur PCC, kinerja keseluruhan pengklasifikasi ditingkatkan karena jumlah atribut berkurang hingga setengahnya. Algoritma ML yang diproses dengan fitur-fitur terpilih ini menunjukkan peningkatan dalam akurasi, sensitivitas, spesifitas, dan waktu prediksi. Tujuan utama dari pekerjaan ini adalah untuk memprediksi secara dini dan akurat fenomena penting di masa depan anak-anak menggunakan model ML. Di masa mendatang, terapkan model hibrida melalui kombinasi algoritme ML dengan teknik pengoptimalan untuk menghasilkan model adaptif untuk diagnosis ASD.

#### Reference

- [1] S R R, Mounika S. Autism Spectrum Disorder Classification Using Machine Learning and Deep Learning- A Survey. EAI Endorsed Trans Pervasive Health Technol. 2023 Oct 26;9.
- [2] Firdaus I, Pradipta RF. Implementasi Treatment and Education of Autistic and Realted Communicationhandicapped Children (TEACCH) pada Kemampuan Bina Diri Anak Down Syndrome. Jurnal ORTOPEDAGOGIA. 2019 Nov 30;5(2):57.
- [3] Hossain MdE, Khan A, Moni MA, Uddin S. Use of Electronic Health Data for Disease Prediction: A Comprehensive Literature Review. IEEE/ACM Trans Comput Biol Bioinform. 2021 Mar 1;18(2):745–58.
- [4] Hashem S, Nisar S, Bhat AA, Yadav SK, Azeem MW, Bagga P, et al. Genetics of structural and functional brain changes in autism spectrum disorder. Transl Psychiatry. 2020 Jul 13;10(1):229.
- [5] Rahman MdM, Usman OL, Muniyandi RC, Sahran S, Mohamed S, Razak RA. A Review of Machine Learning Methods of Feature Selection and Classification for Autism Spectrum Disorder. Brain Sci. 2020 Dec 7;10(12):949.
- [6] Hajjej F, Ayouni S, Alohalie MA, Maddeh M. Novel Framework for Autism Spectrum Disorder Identification and Tailored Education With Effective Data Mining and Ensemble Learning Techniques. IEEE Access. 2024;12:35448–61.
- [7] Rajab KD, Padmavathy A, Thabtah F. Machine Learning Application for Predicting Autistic Traits in Toddlers. Arab J Sci Eng. 2021 Apr 22;46(4):3793–805.
- [8] Alwidian\* J, Elhassan A, Ghnemat R. Predicting Autism Spectrum Disorder using Machine Learning Technique. International Journal of Recent Technology and Engineering (IJRTE). 2020 Jan 30;8(5):4139–43.
- [9] Vakadkar K, Purkayastha D, Krishnan D. Detection of Autism Spectrum Disorder in Children Using Machine Learning Techniques. SN Comput Sci. 2021 Sep 22;2(5):386.



- [10] Kaur A, Kahlon KS. Accurate Identification of ADHD among Adults Using Real-Time Activity Data. *Brain Sci.* 2022 Jun;26(12):831.
- [11] Bala M, Ali MH, Satu MdS, Hasan KF, Moni MA. Efficient Machine Learning Models for Early Stage Detection of Autism Spectrum Disorder. *Algorithms.* 2022 May;16(15):166.
- [12] Al-Salman W, Li Y, Oudah AY, Almaged S. Sleep stage classification in EEG signals using the clustering approach based probability distribution features coupled with classification algorithms. *Neurosci Res.* 2023 Mar;188:51–67.
- [13] Shinde AV, Patil DD. A Multi-Classifier-Based Recommender System for Early Autism Spectrum Disorder Detection using Machine Learning. *Healthcare Analytics.* 2023 Dec;4:100211.
- [14] Chen P, Li F, Wu C. Research on Intrusion Detection Method Based on Pearson Correlation Coefficient Feature Selection Algorithm. *J Phys Conf Ser.* 2021 Jan 1;1757(1):012054.
- [15] Kumar R, Arora R, Bansal V, Sahayashela VJ, Buckchash H, Imran J, et al. Classification of COVID-19 from chest x-ray images using deep features and correlation coefficient. *Multimed Tools Appl.* 2022 Aug 28;81(19):27631–55.
- [16] Entezari-Maleki R, Rezaei A, Minaei-Bidgoli B. Comparison of Classification Methods Based on the Type of Attributes and Sample Size. *J Convergence Inf Technol* [Internet]. 2009;4:94–102. Available from: <https://api.semanticscholar.org/CorpusID:16663667>
- [17] Hashem S, Nisar S, Bhat AA, Yadav SK, Azeem MW, Bagga P, et al. Genetics of structural and functional brain changes in autism spectrum disorder. *Transl Psychiatry.* 2020 Jul 13;10(1):229.
- [18] Hossain MdA, Saiful Islam SM, Quinn JMW, Huq F, Moni MA. Machine learning and bioinformatics models to identify gene expression patterns of ovarian cancer associated with disease progression and mortality. *J Biomed Inform.* 2019 Dec;100:103313.
- [19] Fadi Fabdelja. [https://www.kaggle.com/datasets/fabdelja/asd-screening-data-toddler-child-adoles-adult?select=Autism\\_Screening\\_Data\\_Combined.csv](https://www.kaggle.com/datasets/fabdelja/asd-screening-data-toddler-child-adoles-adult?select=Autism_Screening_Data_Combined.csv). 2025. kaggle.
- [20] Arora N, Kaur PD. A Bolasso based consistent feature selection enabled random forest classification algorithm: An application to credit risk assessment. *Appl Soft Comput.* 2020 Jan;86:105936.
- [21] Abdelmoula AK. Bank Credit Risk Analysis with K-Nearest-Neighbor Classifier: Case of Tunisian Banks. *Journal of Accounting and Management Information Systems* [Internet]. 2015;14(1):79–106. Available from: <https://EconPapers.repec.org/RePEc:ami:journl:v:14:y:2015:i:1:p:79-106>
- [22] Chang YC, Chang KH, Chu HH, Tong LI. Establishing decision tree-based short-term default credit risk assessment models. *Commun Stat Theory Methods.* 2016 Dec 25;45(23):6803–15.
- [23] Boughaci D, Alkhawaldeh AAK, Jaber JJ, Hamadneh N. Classification with segmentation for credit scoring and bankruptcy prediction. *Empir Econ.* 2021 Sep 1;61(3):1281–309.
- [24] Thabtab F, Peebles D. A new machine learning model based on induction of rules for autism detection. *Health Informatics J.* 2020 Mar 29;26(1):264–86.
- [25] Farooq MS, Tehseen R, Sabir M, Atal Z. Detection of autism spectrum disorder (ASD) in children and adults using machine learning. *Sci Rep.* 2023 Jun 13;13(1):9605.

