

EFEKTIVITAS ALGORITMA KECERDASAN BUATAN DALAM IMPLEMENTASI KESEHATAN MENTAL : SYSTEMATIC LITERATURE REVIEW

Dea Kusuma Ningrum, Alya Maytsa Ismawardi

Sistem Informasi, Universitas Pembangunan Nasional "Veteran" Jawa Timur
Jl. Rungkut Madya, Gn. Anyar, Kec. Gn. Anyar, Surabaya, Jawa Timur, Indonesia
deakuzuma24@gmail.com

ABSTRAK

Kesehatan mental merupakan kondisi dimana perkembangan fisik, intelektual, dan emosional yang memungkinkan individu menjalani kehidupan sehari-hari secara optimal. Peningkatan jumlah kasus gangguan mental mendorong pemanfaatan kecerdasan buatan (Artificial Intelligence/AI) sebagai salah satu upaya untuk mendeteksi gangguan tersebut. Penelitian ini bertujuan untuk menganalisis bagaimana efektivitas penerapan AI dalam mendeteksi gangguan mental melalui pendekatan Systematic Literature Review (SLR). Metode yang digunakan adalah PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) untuk mengklasifikasikan serta menilai kualitas studi yang relevan. Metode ini bertujuan menyusun gambaran komprehensif mengenai tren penelitian, performa algoritma, dan kesenjangan yang ada. Evaluasi mencakup berbagai algoritma AI, seperti Machine Learning, Deep Learning, dan Expert Systems, yang diaplikasikan pada berbagai jenis gangguan mental. Hasil penelitian menunjukkan bahwa algoritma Machine Learning, seperti Random Forest dan Naive Bayes, mencapai tingkat akurasi hingga 96% saat digunakan untuk menganalisis data terstruktur. Di sisi lain, algoritma Deep Learning, seperti LSTM (Long Short-Term Memory) dan BiLSTM (Bidirectional LSTM), memberikan akurasi hingga 94,12% dalam mengolah data tidak terstruktur. Sementara itu, Expert Systems memberikan hasil yang lebih baik pada diagnosis awal, terutama untuk gejala yang jelas dan dapat diprediksi. Penelitian ini diharapkan dapat memberikan wawasan mendalam mengenai efektivitas dan keandalan teknologi AI dalam mendukung deteksi dini gangguan mental.

Kata kunci : Deteksi kesehatan mental; Artificial Intelligence; Machine Learning; Deep Learning; Expert Systems

1. PENDAHULUAN

Di era revolusi industri 4.0 seperti sekarang ini, kesehatan mental telah menjadi isu krusial di tingkat global yang membutuhkan penanganan yang lebih mendalam dan serius. Kesehatan mental adalah kondisi dimana seseorang mengalami perkembangan dan pertumbuhan secara fisik, intelektual, dan emosional sehingga dapat menjalani kehidupannya secara matang dan bertanggung jawab, serta beradaptasi dengan aturan sosial dan daya tahan terhadap tekanan kehidupan yang dialaminya[1].

Berbagai gangguan kesehatan mental, seperti depresi, kecemasan, dan stres kronis, semakin meningkat di seluruh dunia dan mempengaruhi jutaan orang dari berbagai latar belakang. Menurut hasil laporan SKI 2023 dari Kemenkes BKKP terdapat gangguan jiwa yang diderita masyarakat Indonesia diantaranya, skizofrenia (3% telah terdiagnosis namun sebanyak 4% menunjukkan gejala dari total sampel 315.621 ART (Anggota Rumah Tangga), depresi (1,4% dari 630.827 penduduk berusia ≥ 15 tahun), serta berkeinginan bunuh diri sebanyak 0,25% dari total 630.827 sampel). Dengan jumlah masyarakat yang memanfaatkan fasilitas dapat diketahui dengan proporsi rumah tangga di Indonesia yang tidak menggunakan fasilitas kesehatan untuk ART gangguan jiwa psikotik atau skizofrenia sekitar 8,4%, depresi yang berobat sekitar 12,7%[2].

Kurangnya ketersediaan fasilitas dan edukasi terhadap para orangtua serta stigma negatif tentang

gangguan mental yang beredar mengakibatkan tidak sedikit masyarakat yang mengalaminya enggan mencari bantuan. Oleh karena itu, dibutuhkan solusi teknologi untuk membantu proses diagnosa secara lebih luas dan mudah diakses.

Kecerdasan buatan (Artificial Intelligence) memiliki potensi besar dalam mendukung upaya peningkatan kesehatan mental dalam ranah teknologi. AI sendiri berpotensi dalam mendeteksi berbagai pola yang ada dalam data. Kemampuan AI dalam menganalisis data dengan cepat dan akurat dapat membantu mengidentifikasi gejala gangguan kesehatan mental berdasarkan interaksi pribadi dengan perangkat digital. Beberapa penelitian yang menggunakan AI menunjukkan bahwa algoritma AI dapat digunakan untuk memprediksi gejala awal, dengan tingkat hasil yang baik jika digunakan untuk diagnosis dini gejala yang jelas dan dapat diprediksi. Studi ini menyoroti pentingnya memilih algoritma yang tepat dalam deteksi dini gangguan mental.

Beberapa penelitian sebelumnya telah membangun sistem pendukung yang menggunakan kecerdasan buatan untuk membantu diagnosa gangguan kesehatan mental. Berdasarkan penelitian yang membahas tentang kombinasi algoritma C4.5 dan optimasi partikel biner (Binary Particle Swarm Optimization/BPSO) untuk mendeteksi penyakit Alzheimer[3].

Kemudian pada penelitian artificial intelligence yang digunakan berbasis perangkat wearable untuk

mendeteksi stress pada anak dengan memberi peringatan kepada pengawas melalui aplikasi monitoring atau SMS[4].

Kemajuan artificial intelligence khususnya machine learning memungkinkan pengenalan pola secara otomatis dari besar data. Algoritma machine learning seperti deep learning, support vector machine (SVM), dan decision tree telah berhasil diterapkan pada berbagai bidang kedokteran, termasuk deteksi penyakit berdasarkan gejala klinis pasien. Penelitian ini bertujuan untuk menganalisis algoritma machine learning yang potensial untuk diterapkan pada sistem deteksi gangguan mental berbasis kecerdasan buatan.

Literature review tentang kecerdasan buatan pada kesehatan mental menggunakan systematic analysis of literature review menggunakan panduan PRISMA telah dilakukan oleh beberapa studi [5], [6].

Penelitian ini bertujuan memperluas pemahaman tentang penggunaan kecerdasan buatan (AI) dalam mendeteksi kesehatan mental di semua usia. Metode Systematic Literature Review (SLR) digunakan untuk mengumpulkan, menyeleksi, dan mengevaluasi studi relevan secara sistematis. SLR membantu mengidentifikasi tren, kesenjangan penelitian, serta menilai efektivitas AI dalam deteksi kesehatan mental secara komprehensif dan kritis.

Proses pelaporan dalam penelitian ini menggunakan standar PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses). PRISMA adalah panduan pelaporan yang membantu meningkatkan transparansi dan konsistensi dalam proses seleksi dan pelaporan hasil penelitian. Penelitian ini melaporkan setiap tahapan proses seleksi literatur, mulai dari identifikasi artikel, penyaringan, hingga evaluasi akhir, untuk memastikan proses review yang akurat dan dapat dipertanggungjawabkan. Dengan demikian, hasil kajian ini diharapkan dapat menjadi referensi yang berguna bagi peneliti, praktisi, dan pengembang aplikasi AI di bidang kesehatan mental untuk merancang sistem yang lebih efektif, aman, dan etis. dapat memberikan kontribusi terhadap peningkatan pelayanan kesehatan jiwa di Indonesia secara umum. Serta dapat memfasilitasi diagnosa awal gangguan mental secara lebih luas, cepat, dan akurat berkat kecerdasan sistem yang dikembangkan

2. TINJAUAN PUSTAKA

2.1. Sytematic Litratue Review (SLR)

SLR Merupakan sebuah teknik sistematis yang digunakan untuk mengumpulkan, menguji secara kritis, serta mengintegrasikan hasil dari berbagai kajian penelitian terkait pertanyaan atau topik yang ingin dieksplorasi lebih dalam [7].

Terdapat empat tahapan yang digunakan pada Systematic Literature Review, yaitu Pertama, tahap Perencanaan, di mana review question dan metode ditentukan. Selanjutnya, tahap Pengumpulan Data, yang meliputi pencarian kata kunci, penyaringan judul dan abstrak, penilaian serta penyaringan, dan ekstraksi data. Kemudian, masuk ke tahap Analisis, yang

mencakup analisis deskriptif dan tematik. Akhirnya, semua proses ini diakhiri dengan tahap Sintesis, yang melibatkan diskusi hasil temuan.

2.2. Artificial Intelligence (AI)

Kecerdasan buatan, atau yang lebih dikenal sebagai Artificial Intelligence (AI), merupakan sebuah cabang ilmu komputer yang berfokus pada pengembangan sistem dan mesin yang dapat melaksanakan tugas-tugas yang umumnya memerlukan kecerdasan manusia. AI ini dirancang untuk memungkinkan komputer berpikir, belajar, dan bertindak layaknya manusia[8].

2.3. Kesehatan Mental

Menurut World Health Organization (WHO) yang tertera pada ITJEN KEMENDIKBUD, kesehatan mental merupakan keadaan sejahtera di mana seseorang menyadari kemampuan dirinya, mampu mengelola stres, beradaptasi dengan baik, bekerja secara produktif, serta berkontribusi positif kepada lingkungan sekitar[9].

Kesehatan mental sendiri penting karena hal tersebut dapat mempengaruhi bagaimana seseorang memandang dirinya, lingkungan, dan bagaimana mereka memahami lingkungan sekitar.

3. METODE PENELITIAN

Penelitian ini menggunakan metode Systematic Literature Review (SLR) dengan panduan PRISMA sebagai sarana penelitian. Literature review ini menggunakan pendekatan sistematis dan proses seleksi dalam penyeleksian artikel yang akan digunakan nantinya. Penelitian ini berfokus pada bagaimana Artificial Intelligence (AI) digunakan dalam mendeteksi Kesehatan mental khususnya gangguan mental.

3.1. Identifikasi

Pencarian komprehensif dilakukan menggunakan database Google Scholar. Kata kunci yang digunakan seperti "AI", "Kesehatan mental", "Deteksi gangguan mental", dan sejenisnya. Artikel yang digunakan haruslah artikel dalam 5 tahun terakhir. Nantinya, diharapkan artikel-artikel tersebut dapat menjawab beberapa pertanyaan penelitian yang ada pada Tabel 1.

Tabel 1. Research Question

ID	Research Question (RQ)
RQ1	Seberapa efektif AI dalam mendeteksi berbagai jenis gangguan mental, seperti depresi, kecemasan, atau gangguan bipolar, dan apakah pendekatan AI tertentu lebih unggul untuk jenis gangguan tertentu?
RQ2	Apa perbedaan utama dalam penggunaan algoritma AI (seperti Machine Learning, Deep Learning, dan Natural Language Processing) dalam mendeteksi gangguan mental?

3.2. Screening dan Eligibility

Selanjutnya Artikel yang digunakan untuk review harus memenuhi beberapa kriteria, seperti

- Makalah yang diterbitkan dalam lima tahun terakhir (2019-2024)
- Penelitian yang melibatkan penggunaan algoritma, dll. Pembelajaran mesin, pembelajaran mendalam, pemrosesan bahasa alami, dan teknik ai lainnya
- Makalah tentang penggunaan atau evaluasi teknologi ai dalam deteksi atau pengobatan gangguan mental
- Jurnal ilmiah
- Makalah yang mengevaluasi efektivitas algoritma ai dalam mendeteksi gangguan jiwa. Penelitian yang mencakup hasil empiris seperti uji klinis, eksperimen, dan evaluasi untuk evaluasi
- Jurnal ilmiah dan/atau prosiding konferensi mempunyai akses teks lengkap yang terbuka. Kriteria eksklusi dalam penelitian ini merupakan kebalikan dari kriteria inklusi.

3.3. Ekstraksi Data

Artikel yang tersisa tadi akan melalui proses penyaringan lanjutan untuk memastikan kualitas dari artikel tersebut sehingga nantinya didapatkan artikel yang relevan dengan penelitian ini. Beberapa kriteria yang digunakan dalam pemilihan artikel ditunjukkan pada Table 2.


Tabel 2. Question Pemilihan Artikel

ID	Question
Q1	Apakah studi tersebut menggunakan metodologi yang tepat dan rinci untuk penerapan AI dalam deteksi kesehatan mental?
Q2	Apakah data yang digunakan dalam penelitian bersifat valid dan representatif untuk deteksi gangguan mental?
Q3	Apakah hasil dan evaluasi performa AI dijelaskan dengan metrik yang jelas (misalnya, akurasi, sensitivitas, spesifisitas)?
Q4	Apakah penelitian tersebut mengidentifikasi tantangan atau keterbatasan dalam penerapan AI untuk kesehatan mental?
Q5	Apakah penelitian tersebut menyajikan rekomendasi untuk pengembangan atau implementasi lebih lanjut dalam penggunaan AI untuk kesehatan mental?
Q6	Apakah tujuan dan pertanyaan penelitian dijelaskan dengan jelas dan telah terjawab dalam studi ini?

Hasil dari penyaringan lanjutan didapatkan sekitar 20 artikel yang memenuhi kriteria dari pertanyaan-pertanyaan di atas disajikan dalam *JBICritical Appraisal* sebagai berikut. Penilaian literatur menggunakan JBI Checklist Tool menunjukkan bahwa studi yang dianalisis memenuhi setidaknya 60% dari total kriteria yang digunakan. Dari 6 kriteria yang dievaluasi, minimal 4 kriteria berhasil terpenuhi oleh setiap studi. Hal ini menandakan bahwa studi-studi

tersebut telah menunjukkan tingkat kualitas yang memadai dalam hal validitas internal, metodologi yang digunakan, serta penerapan yang sesuai dengan standar penelitian ilmiah.

3.4. Analisis Data



Gambar 1. Analisis data menggunakan PRISMA

Pada Gambar 1, proses identifikasi, didapatkan sekitar 1.170 artikel dari hasil pencarian pada Google Scholar menurut keyword yang telah ditentukan. Setelah melewati tahapan identifikasi, artikel masuk pada tahapan screening. Pada tahapan ini ada sekitar 370 artikel yang telah disaring. Selanjutnya untuk tahapan eligibility, ada sekitar 220 artikel yang dikecualikan dan menyisakan 150 artikel. Pada tahapan selanjutnya artikel disaring lebih lanjut dan mengecualikan 130 artikel dan hanya menyisakan 20 artikel yang benar-benar sesuai berdasarkan kriteria yang telah ditentukan.

4. HASIL DAN PEMBAHASAN

Hasil penelitian kualitas literature dan ekstraksi data yang telah dilakukan, diketahui kesehatan mental yang dapat diagnosa menggunakan algoritma *artificial intelligence* diantaranya adalah tingkat stress, mengidentifikasi gejala-gejala ADHD, depresi, kecemasan, serangan panik berdasarkan dataset, analisis sentiment, dan banyak lagi. Metode deteksi gangguan ini beragam, dari penggunaan data gejala yang dilaporkan oleh pasien berasal dari survei, dataset publik dari sebuah platform terpercaya atau oleh lembaga penelitian atau pemerintah mengenai kesehatan mental, data medis, hasil wawancara, atau analisis teks dari media sosial seperti twitter serta menggunakan perangkat wearable (seperti smartwatch) untuk mengumpulkan data fisiologis.

4.1. Efektivitas Algoritma Artificial Intelligence berdasarkan Performa dan Akurasi

Peneliti menganalisis efektivitas algoritma Artificial Intelligence (AI) dalam mendiagnosis gangguan kesehatan mental berdasarkan aspek performa dan akurasi, yang dibagi menjadi tiga kategori pendekatan: *Machine Learning*, *Deep Learning*, dan *Expert Systems*. Dari 20 jurnal yang

digunakan, terdapat 12 literatur yang berfokus pada algoritma *Machine Learning*, 4 literatur mengenai algoritma *Deep Learning*, serta 5 literatur terkait *Expert Systems*. Selain itu, terdapat satu jurnal yang mencakup kedua pendekatan, *Deep Learning* dan *Machine Learning*, dalam implementasi diagnosis kesehatan mental.

Tabel 3. Implementasi Metode Artificial Intelligence Machine Learning berdasarkan aspek performa dan akurasi

Reference	Aspek Performa dan Akurasi Algoritma
[10]	Metode Naive Bayes digunakan untuk mengklasifikasikan hubungan antara gejala ADHD dan diagnosis ADHD. Hasil evaluasi menunjukkan bahwa sistem pakar yang dibangun dapat mendiagnosis ADHD dengan akurasi 87%. Akurasi tersebut menunjukkan bahwa metode Naive Bayes dapat memprediksi diagnosis dengan baik berdasarkan gejala yang ditanyakan pengguna.
[4]	Algoritma yang digunakan adalah naive bayes dan decision tree digunakan untuk melatih Algoritma klasifikasi kelas yaitu stres dan tidak stres.=> Algoritma Naive Bayes mampu mengklasifikasikan data dengan akurasi 80% pada training set dan 81,25% pada testing set. Waktu komputasi Algoritma ini relatif cepat. => Algoritma Decision Tree mampu mengklasifikasikan data dengan akurasi 85% pada training set dan 82,5% pada testing set. Walaupun lebih akurat dari Naive Bayes, waktu komputasi Algoritma ini lebih lama.
[11]	Algoritma <i>Naive Bayes Classifier</i> untuk melakukan pengklasifikasian sentiment pada data tweet. Peneliti melakukan split data dengan perbandingan 80:20 untuk data latih dan data uji. Peneliti dapat memastikan bahwa Algoritma yang dihasilkan tidak hanya bekerja baik pada data latih, tetapi juga mampu memberikan hasil klasifikasi yang akurat pada data baru (data uji) yang belum pernah dilihat sebelumnya oleh Algoritma. Nilai akurasi yang diperoleh sebesar 90,24% menunjukkan bahwa algoritma <i>Naive Bayes Classifier</i> cukup efektif dalam mengklasifikasikan sentimen pada data tweet terkait isu bunuh diri mahasiswa.
[12]	Algoritma IndoBERT adalah adaptasi BERT untuk data teks Bahasa Indonesia, yang menunjukkan performa yang efektif dalam potensi depresi dari teks di media sosial. Data diberi label menggunakan Algoritma klasifikasi emosi IndoBERT, dengan emosi negatif dikategorikan sebagai depresi dan emosi positif sebagai normal. Hasil terbaik menunjukkan akurasi, precision, recall, dan F1-score mencapai 94,91%. Ini menunjukkan bahwa Algoritma IndoBERT mampu memahami konteks dan nuansa bahasa Indonesia dengan baik sehingga efektif dalam mendeteksi potensi depresi.
[13]	Menggunakan 2 metode yakni K-Nearest Neighbor (KNN) dan Naive Bayes dengan data dibagi menjadi data latih (80%) dan data uji (20%). Hasil penelitian ditemukan bahwa 35% mengalami depresi, 34% mengalami kecemasan, dan 33% mengalami serangan panik. Dimana metode KNN menunjukkan akurasi sebesar 85% untuk kecemasan, 80% untuk depresi, dan 80% untuk serangan panik. Sedangkan metode Naive Bayes menunjukkan akurasi sebesar 75% untuk kecemasan dan depresi, dan 70% untuk serangan panik. Dapat disimpulkan bahwa metode KNN memiliki performa yang lebih baik dan lebih sesuai untuk digunakan dalam mengklasifikasi kondisi kesehatan mental mahasiswa berdasarkan dataset yang digunakan dalam penelitian ini.
[14]	Metode yang digunakan adalah Random Forest untuk mengklasifikasikan diagnosis Kesehatan mental, yang terdiri dari 120 data pasien dengan 17 atribut, diberi label oleh dokter dengan 4 kategori penyakit mental : depresi, bipolar tipe 1, bipolar tipe 2, dan normal. Akurasi diperoleh hasil terbaik dari 5 kali percobaan dengan akurasi 90,83%, precision 93,25%. Dengan Parameter terbaik yang ditemukan melalui tuning adalah n-estimator 30, maximum depth 4, minimum sample split 10. Kombinasi parameter ini menghasilkan performa klasifikasi yang optimal.
[15]	Menggunakan tiga algoritma klasifikasi yakni KNN (K-Nearest Neighbor), Decision Tree, dan SVM (Support Vector Machine) untuk mendeteksi tingkat stres manusia berdasarkan kualitas tidur. Pada metode KNN dan SVM, penelitian ini menghasilkan nilai Accuracy, Precision, Recall, dan F1-score sebesar 100%. Pada metode Decision Tree, penelitian ini menghasilkan Accuracy sebesar 99% dan Precision, Recall, F1-score sebesar 100%. Hasil penelitian menunjukkan bahwa semua Algoritma klasifikasi memiliki performa yang sangat baik dalam mendeteksi tingkat stres. Perbedaan ini dapat disebabkan oleh karakteristik masing-masing algoritma dalam membangun Algoritma yang optimal berdasarkan data yang diberikan.
[16]	Algoritma yang digunakan untuk klasifikasi teks untuk mendeteksi depresi dan kecemasan pada pengguna Twitter yakni Decision Tree, Random Forest, Naive Bayes, dan K-Nearest Neighbor (KNN) dengan splitting data menjadi 80% data latih dan 20% data uji. Hasil eksperimen menunjukkan bahwa algoritma Random Forest dengan split 80:20 memiliki performa terbaik dengan nilai akurasi 0.957 atau 96%. Algoritma Decision Tree, Naive Bayes, dan KNN juga diuji, namun hasilnya tidak sebaik algoritma Random Forest.
[17]	Penelitian ini menggunakan metode kombinasi LSTM (Long Short-Term Memory) dan RNN (Recurrent Neural Network) untuk klasifikasi teks dalam mendeteksi depresi pada tweet Twitter Indonesia. LSTM-RNN dipilih karena telah menunjukkan performa yang baik pada penelitian sebelumnya terkait identifikasi komentar kasar di media sosial Indonesia dengan nilai presisi, recall, dan F1-score masing-masing sebesar 86%, 86%, dan 86%. Sementara itu, akurasi Algoritma mencapai 86%.
[18]	Penelitian ini bertujuan untuk membandingkan algoritma machine learning dalam klasifikasi penyakit skizofrenia sebagai sebuah kondisi mental yang sering sulit untuk didiagnosis dengan menggunakan pendekatan dengan menerapkan Algoritma Logistic Regression yang dilatih dengan data medis dan psikologis dari pasien skizofrenia. Hasil

Reference	Aspek Performa dan Akurasi Algoritma
	akurasinya sebesar 93,6% dengan nilai loss pada data uji adalah 0,67 mengindikasikan kemampuan generalisasi data baru. Ini menunjukkan bahwa Algoritma Logistic Regression memiliki performa yang baik dalam mengklasifikasi penyakit skizofrenia berdasarkan data yang digunakan dalam penelitian. Algoritma lain yang digunakan untuk perbandingan yakni k-NN dengan akurasi sebesar 65,77%. Penggunaan data EEG dan fitur-fitur yang diekstraksi terbukti efektif dalam mengidentifikasi pola-pola yang membedakan antara pasien skizofrenia dan kontrol.
[19]	Penelitian ini menggunakan 3 algoritma yakni LightGBM, CatBoost, dan Regresi Logistik dalam mendiagnosis gangguan psikiatri menggunakan dataset EEG. Dengan akurasi kinerja yakni, LightGBM mencapai akurasi 98%, presisi 97%, recall 97%, dan skor F1 98% - lebih tinggi dari CatBoost (85%, 83%, 85%, 84%) dan Regresi Logistik (81%, 79%, 83%, 80%). Analisis menunjukkan bahwa LightGBM dapat dengan akurat dan akurasi lebih tinggi mengidentifikasi kasus positif dan negatif, serta memiliki tingkat kesalahan yang rendah, sehingga lebih handal untuk diagnosis gangguan psikiatri. Meskipun CatBoost juga menunjukkan performa yang baik, Regresi Logistik memiliki akurasi dan metrik kinerja yang lebih rendah dibandingkan dua model lainnya.
[20]	Algoritma yang digunakan adalah Extreme Gradient Boost (XGBoost) dan Random Forest dalam mengklasifikasi data kesehatan mental berdasarkan pengobatan, stress yang bertambah, perubahan kebiasaan, riwayat kesehatan mental, perubahan mood, wawancara kesehatan mental, dan pilihan perawatan. Dalam 30 kali percobaan, algoritma XGBoost memiliki rata-rata nilai akurasi, presisi, recall, dan f1-score sebesar 99.82%. Sementara itu, algoritma Random Forest memiliki rata-rata nilai akurasi, presisi, recall, dan f1-score sebesar 99.04% dalam 30 kali percobaan. Hasil penelitian menunjukkan bahwa algoritma Extreme Gradient Boost (XGBoost) memiliki rata-rata nilai akurasi, presisi, recall, dan f1-score yang lebih tinggi dibandingkan dengan algoritma Random Forest.

Berdasarkan pada hasil Tabel 3 menunjukkan bahwa AI dan ML semakin banyak digunakan dalam diagnosis kesehatan mental seperti mendeteksi stres, depresi, dan ADHD. Algoritma seperti Naive Bayes, yang sering digunakan untuk diagnosis ADHD dan analisis sentimen terkait kasus bunuh diri, memiliki kecepatan dan akurasi yang cukup baik, dengan rentang akurasi 75 hingga 90 persen, tetapi masih kalah dalam beberapa kasus dibandingkan dengan algoritma lain. Sementara itu, Decision Tree, yang digunakan untuk klasifikasi stres dan depresi, memiliki akurasi yang lebih tinggi, dengan rentang akurasi 85 hingga 99 persen, meskipun memerlukan waktu komputasi yang lebih lama. Random Forest juga populer dengan akurasi 90.83%–96%, yang menjadikannya salah satu algoritma terbaik dalam kategori ini. Ini terutama berlaku untuk analisis data media sosial.

Selain itu, IndoBERT, yang didedikasikan untuk bahasa Indonesia, memiliki akurasi 94.91% dalam mendeteksi potensi depresi di platform media sosial. Keunggulan algoritma ini adalah kemampuan untuk mengidentifikasi nuansa bahasa lokal, yang membuatnya unggul dalam analisis teks Bahasa

Indonesia. Algoritma K-Nearest Neighbor (KNN), yang digunakan untuk mengklasifikasi kesehatan mental siswa, cenderung memiliki akurasi antara 70% dan 85%, tetapi seringkali kurang jika dibandingkan dengan algoritma yang lebih kompleks seperti XGBoost dan Random Forest. Algoritma LSTM-RNN, yang cocok untuk menangani data sekuensial seperti teks di Twitter, memiliki presisi dan recall 86%, tetapi masih di bawah beberapa algoritma lain dalam kategori tersebut.

Logistic Regression juga bekerja dengan baik, terutama dalam klasifikasi skizofrenia, dengan akurasi 93.6%. Namun, itu sedikit lebih buruk daripada LightGBM, jadi masih banyak digunakan dalam kasus sederhana atau ketika waktu komputasi diperlukan. Dengan akurasi 99.82% dan 98%, algoritma yang lebih kompleks seperti XGBoost dan LightGBM menunjukkan kinerja yang unggul untuk data besar dan kompleks. Dari hasil analisis ini, IndoBERT, LightGBM, dan XGBoost muncul sebagai algoritma yang paling akurat dan tepat untuk data yang kompleks, sementara Naive Bayes dan Logistic Regression lebih cocok untuk data sederhana atau ketika efisiensi kompromi diperlukan.

Tabel 4. Implementasi metode artificial intelligence deep learning berdasarkan aspek performa dan akurasi

Reference	Aspek Performa dan Akurasi Metode
[21]	Akurasi pada Algoritma LSTM yang dibangun mencapai akurasi sebesar 93% pada data pelatihan. Serta Validasi akurasi mencapai 82% , menunjukkan performa yang baik meskipun ada sedikit penurunan dari akurasi pelatihan. Dengan nilai loss sebesar 0.3% pada pelatihan dan 1.6% pada validasi menunjukkan bahwa Algoritma ini tidak mengalami overfitting, dan performanya cukup stabil.
[22]	BiLSTM mencapai akurasi 94.12% , yang lebih tinggi dibandingkan dengan semua Algoritma machine learning tradisional yang diuji. Akurasi Precision sekitar 97.59% , menunjukkan tingginya proporsi prediksi positif yang benar. Dengan Recall sekitar 83.86% , yang menunjukkan kemampuan Algoritma dalam mendeteksi kasus positif (pengguna dengan potensi depresi dan kecemasan). Kemudian Training Loss sekitar 18.26% , menunjukkan bahwa Algoritma belajar dengan baik selama pelatihan.
[23]	Algoritma yang digunakan adalah Deep Neural network (DNN) untuk mengklasifikasi 3 jenis gangguan mental utama, yakni bipolar, depresi mayor, dan sikozaefektif. Hasil evaluasi menunjukkan

Reference	Aspek Performa dan Akurasi Metode
	MHDeep mencapai akurasi rata-rata pengujian sebesar 90,4%, 87,3%, dan 82,4% masing-masing untuk klasifikasi antara sehat-skizoafektif, sehat-depresi mayor, dan sehat-bipolar. Sedangkan pada evaluasi level pasien, Algoritma DNN MHDeep mencapai akurasi 100%, 100%, dan 90,0% untuk ketiga gangguan kesehatan mental tersebut, berdasarkan inferensi menggunakan 40, 16, dan 22 menit data sensor. Algoritma DNN yang disintesis oleh MHDeep ((yang memanfaatkan sensor medis yang terpasang di perangkat wearable (smartwatch dan smartphone)) dirancang agar cukup efisien secara komputasi sehingga dapat diimplementasikan pada perangkat tepi (edge device) seperti smartphone.
[17]	Penelitian ini menggunakan metode kombinasi LSTM (Long Short-Term Memory) dan RNN (Recurrent Neural Network) untuk klasifikasi teks dalam mendeteksi depresi diklasifikasikan antara kondisi depresi dan normal pada tweet Twitter Indonesia. Namun, kondisi normal kesulitan diidentifikasi karena tren tweet berlabel normal terlalu rumit untuk dipelajari modelnya. LSTM-RNN dipilih karena telah menunjukkan performa yang baik pada penelitian sebelumnya terkait identifikasi komentar kasar di media sosial Indonesia dengan nilai presisi, recall, dan F1-score masing-masing sebesar 86%, 86%, dan 86%. Sementara itu, akurasi Algoritma mencapai 86%. Algoritma lain yang digunakan sebagai perbandingan yakni LTSM- Glove CNN sekitar akurasi, presisi, recall, dan F1- score masing-masing sebesar 46%, 33%, 38%, 35%.

Pada Tabel 4, secara keseluruhan, tampaknya metode BiLSTM dan MHDeep dengan DNN paling efektif dalam deteksi data teks dan berbasis sensor; keduanya menawarkan akurasi tinggi dan stabilitas di berbagai jenis data kesehatan mental. Karena kemampuan kedua algoritma tersebut untuk menangani kompleksitas data dan pola temporal yang penting untuk analisis kesehatan mental, algoritma Bidirectional Long Short-Term Memory (BiLSTM) dan MHDeep dengan Deep Neural Network (DNN) menjadi sangat efektif dalam deteksi teks dan berbasis sensor. BiLSTM memiliki kemampuan untuk membaca data dari dua arah, yang memungkinkan algoritma ini untuk menganalisis konteks sekitar kata-kata dengan lebih akurat. Ini memungkinkan algoritma ini untuk mengidentifikasi pola bahasa atau emosi yang menunjukkan depresi atau kecemasan dengan lebih akurat.

Sedangkan karena jaringan neuralnya yang dalam, MHDeep dengan DNN sangat baik untuk menganalisis data sensor. Pola yang lebih kompleks seperti ritme jantung atau pola tidur dapat dipelajari oleh algoritma ini. Algoritma DNN MHDeep dirancang untuk meningkatkan efisiensi komputasi, memungkinkannya digunakan pada perangkat tepi (edge devices) seperti smartphone, yang memungkinkan pengguna melakukan deteksi real-time yang bermanfaat. Hasil yang sangat baik, terutama pada tingkat pasien, menunjukkan bahwa algoritma ini dapat membedakan kondisi mental yang berbeda dengan sangat presisi. Kesuksesan pendeteksian kesehatan mental berbasis teks dan sensor bergantung pada struktur model yang mampu mengidentifikasi pola dan karakteristik khusus yang diperlukan untuk memahami berbagai jenis data kesehatan mental.

Tabel 5, implementasi metode artificial intelligence expert system berdasarkan aspek performa dan akurasi

Reference	Aspek Performa dan Akurasi Metode
	Performa Sistem yang dikembangkan menggunakan PHP dan MySQL, yang memungkinkan akses melalui web. Ini memberikan kemudahan bagi pengguna untuk melakukan konsultasi tanpa harus mengunjungi fasilitas kesehatan secara langsung. Proses input dan output dalam sistem dirancang agar user-friendly, sehingga dapat digunakan oleh masyarakat luas.
[24]	Akurasi Meskipun sistem ini menunjukkan kemampuan untuk memberikan diagnosis berdasarkan gejala yang diberikan, akurasi hasil yang diperoleh dari pengujian terbatas. Dalam penelitian sebelumnya yang dirujuk, sistem dengan metode Certainty Factor menunjukkan akurasi 100% berdasarkan 30 data uji. Namun, dalam penelitian ini, hanya ada satu hasil diagnosis yang dilaporkan dengan tingkat kepastian 56%. Ini menunjukkan bahwa meskipun sistem dapat memberikan hasil, akurasi dan kehandalan diagnosis mungkin perlu ditingkatkan melalui pengujian lebih lanjut dan perluasan basis data gejala dan gangguan mental.
[25]	Pengujian dilakukan Manual dan Aplikasi: Misalkan dari 30 data yang diuji, semua data menunjukkan hasil yang konsisten antara pengujian manual dan hasil aplikasi. Maka, akurasi dapat dihitung dari hasil jumlah data akurat dibagi total data kemudian dikalikan 100% jika 30 data tersebut akurat, maka akurasi pengujian masalah mental emosional pada anak pada anak. Hasil dari pengolahan data menggunakan metode Forward Chaining menghasilkan tiga klasifikasi untuk setiap kategori: normal, borderline, dan abnormal
[26]	Pengujian sistem dilakukan dengan menggunakan 10 kasus eksperimen, dan hasilnya menunjukkan bahwa hampir seluruh deteksi yang dihasilkan oleh sistem sesuai dengan diagnosis yang diberikan oleh pakar. sistem pakar telah diuji menggunakan metode black box dan User Acceptance Test (UAT). Hasil pengujian black box menunjukkan tingkat validasi 100%, mengindikasikan bahwa semua fungsi sistem

Reference	Aspek Performa dan Akurasi Metode
	berjalan dengan baik dan sesuai dengan yang diharapkan. Dalam UAT, sistem mendapatkan rata-rata nilai 90,7%, yang tergolong sangat baik. Responden, yang terdiri dari pakar dan mahasiswa, menilai kinerja sistem dengan positif, menunjukkan penerimaan yang baik terhadap sistem ini.
[27]	Penelitian ini mengimplementasikan Algoritma Logika Fuzzy dengan aturan Fuzzy Mamdani untuk sistem pendeteksi stress dengan empat tingkatan stress, yakni “Rileks”, “Tenang”, “Cemas”, dan “Tegang”. Berdasarkan evaluasi performa sistem pendeteksi stres yang dilakukan menggunakan kalibrasi pada software Matlab, diperoleh nilai error rata-rata sebesar 7,5%. Dengan demikian, tingkat akurasi sistem pendeteksi stres ini adalah 92,5%. Hal ini menunjukkan bahwa metode Logika Fuzzy efektif diterapkan dalam sistem pendeteksi stres pada manusia.
[28]	Penelitian ini menggunakan pendekatan sistem berbasis aturan dengan metode Dempster Shafer untuk mendiagnosa jenis gangguan jiwa dengan 9 jenis gangguan jiwa yakni <i>Schizophrenia paranoid</i> , <i>Depressive unspecified</i> , <i>Acute and transient psychotic disorder unspecified</i> , <i>Unspecified mental disorder due to brain damage and physical disease</i> , <i>Panic disorder</i> , <i>Autism syndrome disorder</i> , <i>Psychomatic disorder unspecified</i> , <i>Anxiety disorder dementia</i> , <i>Unspecified dementia</i> . Pengujian dengan membagi data ke dalam 10 fold dengan akurasi indexing Dempster Shafer: 81,01% serta Pengujian dengan membagi data secara acak ke dalam 3 kelompok (9:1, 8:2, dan 7:3), masing-masing dilakukan 20 kali sebesar 85,21%, 82,01%, 78,82%. Hasil akurasi indexing yang cukup tinggi menunjukkan bahwa metode Dempster Shafer dapat digunakan secara efektif untuk mendiagnosis jenis gangguan jiwa berdasarkan gejala-gejala yang dialami oleh pasien. terdapat beberapa kasus di mana akurasi indexing menurun, Hal ini disebabkan oleh ketidakseimbangan data kasus pada setiap jenis gangguan jiwa.

Tabel 5 menyajikan perbandingan metode *Expert System* dalam deteksi kesehatan mental, yang melibatkan berbagai pendekatan seperti *Certainty Factor*, *Forward Chaining*, *Rule-Based Reasoning*, *Fuzzy Logic*, dan *Dempster Shafer*. Algoritma *Certainty Factor*, meskipun berguna dalam aplikasi berbasis web dengan diagnosis otomatis, kurang efektif untuk aplikasi yang membutuhkan konsistensi tinggi karena akurasinya yang fluktuatif dan tergantung pada kualitas data yang digunakan. Algoritma *Forward Chaining* cocok untuk klasifikasi sederhana dengan kategori terbatas, seperti dalam deteksi gangguan mental emosional pada anak, namun mungkin tidak cukup fleksibel untuk kasus yang lebih kompleks. Algoritma *Rule-Based Reasoning* menunjukkan efektivitas yang sangat tinggi, dengan akurasi dan penerimaan pengguna yang optimal, menjadikannya pilihan yang tepat untuk aplikasi yang membutuhkan stabilitas dan konsistensi, seperti pada deteksi gangguan mental pada mahasiswa. *Fuzzy Logic* sangat efektif untuk aplikasi yang memerlukan pengukuran subjektif, seperti stres, karena dapat menangani ketidakpastian dan menghasilkan kategori yang lebih fleksibel. Sementara itu, *Dempster Shafer* unggul dalam mendiagnosis gangguan mental kompleks, seperti skizofrenia atau gangguan kecemasan, dengan akurasi yang tinggi, meskipun akurasinya dapat menurun jika data tidak seimbang. Oleh karena itu, pemilihan metode yang tepat sangat bergantung pada kebutuhan spesifik aplikasi, dengan

Rule-Based Reasoning untuk kestabilan, *Fuzzy Logic* untuk pengukuran variabel subjektif, dan *Dempster Shafer* untuk diagnosis dengan gejala yang beragam dan kompleks.

4.2. Perbedaan Penggunaan Jenis Algoritma Kecerdasan Buatan dalam Mendeteksi Kesehatan Mental

Terdapat perbedaan mendasar antara berbagai jenis kecerdasan buatan (AI) dan algoritma yang digunakan dalam setiap kategori untuk mendukung aplikasi yang spesifik seperti deteksi kesehatan mental. Setiap jenis AI memiliki pendekatan yang berbeda dalam memproses informasi dan menginterpretasi data, tergantung pada kompleksitas dan tujuan analisis yang ingin dicapai. Misalnya, *Machine Learning* menawarkan kemampuan pembelajaran dari data dengan algoritma yang relatif sederhana, sedangkan *Deep Learning* menggunakan jaringan saraf tiruan untuk menangani data lebih kompleks, seperti gambar atau suara. Di sisi lain, *Expert Systems* mengandalkan aturan yang telah ditentukan untuk meniru keputusan seorang ahli. Tabel 3 menjelaskan klasifikasi tiga jenis utama kecerdasan buatan (AI) yang digunakan dalam berbagai aplikasi, khususnya dalam deteksi kesehatan mental.

Tabel 6. Klasifikasi artificial intelligence dalam implementasi metode pendeteksi kesehatan mental

Jenis AI	Pengertian	Algoritma Pendeteksi Kesehatan Mental
Machine Learning	Bidang kecerdasan buatan yang memungkinkan komputer belajar dari data. ML menggunakan algoritma untuk menganalisis data dan menemukan pola. Hal ini memungkinkan komputer membuat keputusan dan prediksi tanpa diprogram secara eksplisit.	1. Decision Tree 2. Naive Bayes 3. K-Nearest Neighbors (KNN) 4. Random Forest 5. Support Vector Machine 6. Logistic Regression 7. XGBoost (Extreme Gradient Boosting)

Jenis AI	Pengertian	Algoritma Pendeteksi Kesehatan Mental
Deep learning	Subbidang Machine Learning yang berfokus pada penggunaan jaringan saraf dalam. Algoritme DL menangkap representasi data secara hierarki dan dapat memproses serta memahami data yang sangat kompleks seperti gambar, teks, dan audio.	1. Long Short-Term Memory (LSTM) 2. BIDIRECTIONAL LSTM 3. Recurrent Neural Network (RNN) 4. Convolutional Neural Network (CNN) 5. IndoBERT 6. DNN (Deep Neural Network)
Expert System	Sebuah program komputer yang meniru pemikiran para ahli di bidang tertentu. Sistem ini menggunakan aturan dan pengetahuan yang ada untuk mengambil keputusan.	1. Forward Chaining 2. Certainty Factor 3. Rule Based Reasoning 4. Fuzzy Logic Systems 5. Dempster Shafer

Tabel 6 memperlihatkan bahwa ketiga jenis kecerdasan buatan (AI) memiliki perbedaan utama dalam cara bekerja dan tipe data yang mampu di proses hingga penyelesaian masalah. Terdapat beberapa parameter yang dapat digunakan untuk membedakan ketiga jenis AI yakni, *machine learning*, *deep learning*, serta *expert system*.

4.2.1. Metode Pembelajaran

Machine Learning (ML) menggunakan pembelajaran berbasis data untuk memahami pola dan melakukan prediksi, dan memproses data historis tanpa menggunakan aturan eksplisit melalui algoritma yang disesuaikan. Berbeda dengan ML yang lebih mendalam, Deep Learning (DL) lebih unggul dalam pemrosesan data yang tidak terstruktur karena menggunakan jaringan saraf tiruan berlapis-lapis untuk menangkap pola yang lebih kompleks. Pada saat yang sama, sistem ahli tidak membutuhkan pembelajaran data sama sekali. Sistem ini bergantung pada sekumpulan aturan yang telah dibuat oleh manusia, yang memungkinkannya berfungsi seperti seorang ahli yang menggunakan pengetahuan khusus untuk membuat keputusan.

4.2.2. Jenis Algoritma yang Digunakan

Pola dari data yang terstruktur ditemukan dan prediksi dibuat dengan algoritma dalam pembelajaran mesin seperti Decision Tree, Naive Bayes, K-Nearest Neighbors (KNN), dan Support Vector Machine. Algoritme seperti Long Short-Term Memory (LSTM), Bidirectional LSTM, dan Convolutional Neural Network (CNN) adalah contoh algoritma deep learning yang memiliki kemampuan untuk memproses data yang tidak terstruktur serta mengenali pola data yang lebih kompleks melalui jaringan saraf berlapis. Namun, jika dibandingkan dengan algoritma, *Expert systems* lebih sederhana karena menggunakan aturan berbasis logika seperti *forward chaining*, faktor keyakinan, dan rasionalisasi berbasis aturan, yang bekerja dengan menerapkan aturan yang sudah ditentukan untuk memecahkan masalah yang sudah diketahui.

4.2.3. Ketergantungan Pada Data

Agar dapat mengenali pola dengan baik dan meningkatkan akurasi prediksi, *machine learning* membutuhkan data yang cukup banyak dan berkualitas. Deep Learning juga menunjukkan

ketergantungan pada data ini, tetapi pada skala yang jauh lebih besar. DL membutuhkan banyak data untuk melatih jaringan sarafnya, terutama ketika menangani data yang tidak terstruktur seperti suara atau gambar. Sebaliknya, sistem ahli tidak memerlukan data historis sama sekali karena bergantung pada aturan logis yang sudah diprogram. Dengan demikian, sistem ahli dapat digunakan tanpa perlu proses pembelajaran data, asalkan aturannya cukup jelas dan lengkap.

4.2.4. Penggunaan Sumber Daya Komputasi

Machine Learning biasanya membutuhkan lebih sedikit sumber daya komputasi dibandingkan dengan Deep Learning, yang bisa menjadi lebih kompleks tergantung pada jumlah data dan jenis algoritma yang digunakan. Deep Learning membutuhkan banyak sumber daya karena jaringan saraf dalamnya perlu melakukan banyak perhitungan pada setiap lapisannya, terutama ketika melibatkan data yang sangat besar. Oleh karena itu, Expert System lebih efektif dalam hal komputasi karena tidak memerlukan proses pelatihan atau pembelajaran. Sistem ini hanya menggunakan logika berbasis aturan, yang lebih mudah diproses dan ideal untuk pengambilan keputusan berbasis aturan yang cepat.

4.2.5. Kemampuan Beradaptasi Terhadap Data Baru

Machine Learning dapat beradaptasi dengan data baru, meningkatkan akurasi prediksinya dari waktu ke waktu. Deep Learning juga dapat beradaptasi dengan data baru, tetapi pembaruan model DL memerlukan lebih banyak waktu dan sumber daya karena kompleksitasnya. Di sisi lain, Expert System tidak dapat beradaptasi dengan data baru karena bekerja berdasarkan aturan yang tetap dan tidak dapat mempelajari data baru. Campur tangan manusia diperlukan untuk memperbarui sistem agar relevan dalam konteksnya apabila aturan atau pengetahuan berubah.

5. KESIMPULAN DAN SARAN

Machine Learning (ML), *Deep Learning* (DL), dan *Expert Systems* memiliki perbedaan utama dalam cara mendeteksi gangguan mental. *Machine Learning* sering digunakan untuk deteksi berbasis pola dalam data yang relatif terstruktur, seperti survei atau penilaian kesehatan mental, yang cocok untuk kasus

depresi atau kecemasan. *Deep Learning*, dengan arsitektur jaringan yang lebih dalam, lebih unggul dalam mengolah data tidak terstruktur seperti teks atau data sensor dan lebih efektif untuk mendeteksi gangguan yang lebih kompleks, seperti gangguan bipolar atau kasus dengan variasi gejala yang dinamis. Sementara itu, *Expert Systems* berbasis aturan lebih cocok untuk skrining awal gangguan mental yang memiliki gejala yang jelas dan dapat diprediksi, seperti depresi. Namun, keterbatasan *Expert Systems* terlihat pada gangguan yang lebih rumit karena kurang fleksibel dalam memproses data yang tidak terstruktur atau variasi gejala.

Secara keseluruhan, AI sangat efektif dalam mendeteksi berbagai gangguan mental, tetapi efektivitasnya bergantung pada kompleksitas dan jenis gangguan. DL menunjukkan keunggulan dalam deteksi gangguan kompleks, seperti bipolar, di mana data tidak terstruktur atau berbasis sensor memainkan peran penting dalam akurasi diagnosis. ML, dengan kecepatan dan akurasi pada data terstruktur, cocok untuk mendeteksi depresi dan kecemasan, terutama dalam skala besar atau untuk penilaian cepat. *Expert Systems* efektif untuk skrining awal gangguan yang jelas berbasis gejala tetapi terbatas untuk analisis gangguan mental yang memerlukan interpretasi mendalam atau analisis data tidak terstruktur. Penelitian selanjutnya diharapkan dapat mengeksplorasi observasi langsung dan cara terbaik untuk mengintegrasikan teknologi AI ini ke dalam sistem layanan kesehatan mental. Misalnya, bagaimana AI dapat membantu proses rujukan ke profesional kesehatan mental berdasarkan hasil diagnosis awal

DAFTAR PUSTAKA

- [1] H. Dessy *et al.*, “KESEHATAN MENTAL PENERBIT CV. EUREKA MEDIA AKSARA,” Jan. 2024. Accessed: Oct. 25, 2024. [Online]. Available: <https://repository.penerbiteitureka.com/media/publications/567795-kesehatan-mental-c3ff1746.pdf>
- [2] B. Kebijakan Pembangunan, K. Kementerian, and K. Ri, “DALAM ANGKA TIM PENYUSUN SKI 2023 DALAM ANGKA KEMENTERIAN KESEHATAN REPUBLIK INDONESIA,” 2023. Accessed: Oct. 25, 2024. [Online]. Available: https://drive.google.com/file/d/1rjNDG_f8xG6-Y9wmhJUnXhJ-vUFevVJC/view
- [3] A. Rosyida and T. B. Sasongko, “Early Detection of Alzheimer’s Disease with the C4.5 Algorithm Based on BPSO (Binary Particle Swarm Optimization),” *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 12, no. 3, pp. 341–349, Nov. 2023, doi: 10.32736/sisfokom.v12i3.1716.
- [4] P. Chyan and Y. Kasmara, “Sistem Monitoring dan Deteksi Stres Pada Anak Berbasis Wearable Device,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 5, pp. 943–949, Oct. 2021, doi: 10.29207/resti.v5i5.3503.
- [5] M. I. Rosadi, T. Yovalwan, and A. Z. Asaduddin, “Artificial intelligence (AI) in efforts to prevent teenage suicide: literature review,” *Media Keperawatan Indonesia*, vol. 7, no. 1, p. 53, Mar. 2024, doi: 10.26714/mki.7.1.2024.53-61.
- [6] Y. Yunike, R. Rehana, M. Misinem, and I. Kusumawaty, “The Implications of Utilizing Artificial Intelligence-Based Parenting Technology on Children’s Mental Health: A Literature Review,” *Poltekita : Jurnal Ilmu Kesehatan*, vol. 17, no. 3, pp. 1083–1099, Nov. 2023, doi: 10.33860/jik.v17i3.2958.
- [7] R. S. Wahono, “A Systematic Literature Review of Software Defect Prediction: Research Trends, Datasets, Methods and Frameworks,” *Journal of Software Engineering*, vol. 1, no. 1, 2015, [Online]. Available: <http://journal.ilmukomputer.org>
- [8] E. S. Eriana, S. Kom, M. Kom, and D. A. Zein, “ARTIFICIAL INTELLIGENCE (AI) PENERBIT CV. EUREKA MEDIA AKSARA.”
- [9] H. Dessy *et al.*, “KESEHATAN MENTAL PENERBIT CV. EUREKA MEDIA AKSARA.”
- [10] N. H. Heryansyah and A. Suryadi, “SISTEM PAKAR DIAGNOSIS ADHD (ATTENTION DEFICIT HYPERACTIVITY DISORDER) PADA ANAK-ANAK MENGGUNAKAN METODE NAÏVE BAYES BERBASIS WEBSITE,” *JORAPI : Journal of Research and Publication Innovation*, vol. 1, no. 4, 2023.
- [11] J. Khatib Sulaiman, A. Rafli, and I. Artikel Abstrak, “Pemanfaatan Analisis Sentimen Terhadap Kasus Bunuh Diri Mahasiswa Menggunakan Naïve Bayes Classifier,” *Indonesian Journal of Computer Science Attribution*, vol. 13, no. 1, pp. 2024–1038.
- [12] G. Fernando Situmorang and R. Purba, “Deteksi Potensi Depresi dari Unggahan Media Sosial X Menggunakan Teknik NLP dan Model IndoBERT,” *Technology and Science (BITS)*, vol. 6, no. 2, 2024, doi: 10.47065/bits.v6i2.5496.
- [13] N. Moningka, M. Hafidurrohman, and W. R. Ajri Tri, “Klasifikasi Mental Mahasiswa Menggunakan Metode Machine Learning,” 2023. [Online]. Available: <https://www.kaggle.com/datasets/shariful07/student-mental->
- [14] A. Priyono, M. Shodiq, D. P. Alvinsyah, and S. A. Hidayah, “METODE RANDOM FOREST UNTUK MEMUDAHKAN KLASIFIKASI DIAGNOSIS PENYAKIT MENTAL,” *Jurnal Informatika Medis (J-INFORMED)*, vol. 2, no. 1, pp. 1–4, Jun. 2024, doi: 10.52060/im.v2i1.2119.
- [15] A. Van Fadhila *et al.*, “Implementasi Metode Machine Learning Untuk Mendeteksi Tingkat Stres Manusia Berdasarkan Kualitas Tidur,” 2023.

- [16] K. Rahayu, V. Fitria, D. Septhya, R. Rahmaddeni, and L. Efrizoni, "Klasifikasi Teks untuk Mendeteksi Depresi dan Kecemasan pada Pengguna Twitter Berbasis Machine Learning," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 3, no. 2, pp. 108–114, Sep. 2023, doi: 10.57152/malcom.v3i2.780.
- [17] Ivan Dwi Nugraha and Y. Azhar, "Deteksi Depresi Pengguna Twitter Indonesia Menggunakan LSTM-RNN," *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, vol. 11, no. 3, pp. 320–329, Dec. 2022, doi: 10.23887/janapati.v11i3.50674.
- [18] K. Nisa and S. Kartika Wibisono, "Klasifikasi Penyakit Skizofrenia menggunakan Algoritma Logistic Regresion," *Jurnal Riset Sistem Informasi Dan Teknik Informatika (JURASIK)*, vol. 8, no. 2, pp. 696–704, 2023, [Online]. Available: <https://tunasbangsa.ac.id/ejurnal/index.php/jurasik>
- [19] W. Munada, D. Khalida Maharani, and A. Sofiana, "PERFORMANCE COMPARISON OF MACHINE LEARNING MODELS TO REDUCE MISDIAGNOSIS RATES IN PSYCHIATRIC DISORDER USING EEG DATASET." [Online]. Available: <https://www.kaggle.com/datasets/bhavikjikadara/mental-health-dataset>
- [20] K. Aditya Ananta Wisnu Wardana and A. A. Mizwar Rahim, "Analisis Perbandingan Algoritma XGBoost Dan Algoritma Random Forest Untuk Klasifikasi Data Kesehatan Mental." [Online]. Available: <https://www.kaggle.com/datasets/bhavikjikadara/mental-health-dataset>
- [21] F. Zakariya, J. Zeniarja, and S. Winarno, "Pengembangan Chatbot Kesehatan Mental Menggunakan Algoritma Long Short-Term Memory," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 8, no. 1, p. 251, Jan. 2024, doi: 10.30865/mib.v8i1.7177.
- [22] K. Setyo Nugroho, I. Akbar, and A. Nizar Suksmawati, "Seminar Nasional Hasil Riset Prefix-RTR DETEKSI DEPRESI DAN KECEMASAN PENGGUNA TWITTER MENGGUNAKAN BIDIRECTIONAL LSTM," 2021.
- [23] S. Hassantabar, J. Zhang, H. Yin, and N. K. Jha, "MHDeep: Mental Health Disorder Detection System Based on Wearable Sensors and Artificial Neural Networks," *ACM Transactions on Embedded Computing Systems*, vol. 21, no. 6, Dec. 2022, doi: 10.1145/3527170.
- [24] N. P. Nopi, Musthafa Haris Munandar, Feri Irawan, and Januardi Rosyidi Lubis, "Sistem Pakar Mendiagnosa Gangguan Mental pada Diri Seseorang Menggunakan Metode Certainty Factor," *Journal of Applied Computer Science and Technology*, vol. 3, no. 1, pp. 157–162, Jun. 2022, doi: 10.52158/jacost.v3i1.307.
- [25] A. Rizkiah, R. D. Risanty, and R. Mujiastuti, "SISTEM PENDETEKSI DINI KESEHATAN MENTAL EMOSIONAL ANAK USIA 4-17 TAHUN MENGGUNAKAN METODE FORWARD CHAINING." [Online]. Available: <https://jurnal.umj.ac.id/index.php/just->
- [26] D. Wahyuni and D. Winarso, "PENERAPAN METODE RULE BASED REASONING DALAM SISTEM PAKAR DETEKSI DINI GANGGUAN KESEHATAN MENTAL PADA MAHASISWA," 2022.
- [27] H. Tari Mokui, dan Wa Ode Siti Nur Alam, and C. Author, "Sistem Pendeteksi Stres pada Manusia Menggunakan Metode Fuzzy Logic Berbasis Internet of Things." [Online]. Available: <https://elektroda.uho.ac.id/>
- [28] V. A. Afeanpah, S. A. S. Mola, and A. Fanggidae, "Case Based Reasoning untuk Mendiagnosa Jenis Gangguan Jiwa Menggunakan Metode Dempster Shafer," *Jurnal Komputer dan Informatika*, vol. 10, no. 1, pp. 9–17, Mar. 2022, doi: 10.35508/jicon.v10i1.6326