

TESIS
ANALISIS PENGARUH PENGATURAN OPTIMASI PADA
ALGORITMA XGBOOST UNTUK MEMPREDIKSI
KESEHATAN MENTAL SISWA SEKOLAH MENENGAH



Disusun oleh:

Nor Riduan

23.55.1382

Digital Transformation Intelligence

FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2026

TESIS

**ANALISIS PENGARUH PENGATURAN OPTIMASI PADA
ALGORITMA XGBOOST UNTUK MEMPREDIKSI
KESEHATAN MENTAL SISWA SEKOLAH MENENGAH**

**ANALYSIS OF THE EFFECT OF OPTIMATION SETTINGS
ON THE XGBOOST ALGORITHM FOR PREDICTING THE
MENTAL HEALTH OF HIGH SCHOOL STUDENTS**

Diajukan untuk memenuhi salah satu syarat mencapai derajat Pascasarjana
Program Studi S2 PJJ Informatika



Disusun oleh:

Nor Riduan

23.55.1382

Digital Transformation Intelligence

**FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2026

HALAMAN PERSETUJUAN

**ANALISIS PENGARUH PENGATURAN OPTIMASI PADA ALGORITMA
XGBOOST UNTUK MEMPREDIKSI KESEHATAN MENTAL SISWA
SEKOLAH MENENGAH**

**ANALYSIS OF THE EFFECT OF OPTIMATION SETTINGS ON THE
XGBOOST ALGORITHM FOR PREDICTING THE MENTAL HEALTH
OF HIGH SCHOOL STUDENTS**

yang disusun dan diajukan oleh

Nor Riduan

NIM 23.55.1382

telah disetujui oleh Dosen Pembimbing Tesis
pada tanggal 07 Januari 2026

Dosen Pembimbing,



Alva Hendi Muhammad, A.Md., S.T., M.Eng., Ph.D.

NIK. 190302493

HALAMAN PENGESAHAN

**ANALISIS PENGARUH PENGATURAN OPTIMASI PADA
ALGORITMA XGBOOST UNTUK MEMREDIKSI KESEHATAN
MENTAL SISWA SEKOLAH MENENGAH**

**ANALYSIS OF THE EFFECT OF OPTIMATION SETTINGS ON
THE XGBOOST ALGORITHM FOR PREDICTING THE MENTAL
HEALTH OF HIGH SCHOOL STUDENTS**

yang disusun dan diajukan oleh

Nor Riduan

23.55.1382

Telah dipertahankan di depan Dewan Penguji
pada tanggal 07 Januari 2026

Susunan Dewan Penguji

Nama Penguji

Tanda Tangan

Tonny Hidayat, S.Kom., M.Kom., Ph.D.
NIK. 190302182



Hanafi, S.Kom., M.Eng., Ph.D.
NIK. 190302024



Alva Hendi Muhammad, A.Md., S.T., M.Eng., Ph.D.
NIK. 190302493



Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer
Tanggal 07 Januari 2026

DEKAN FAKULTAS ILMU KOMPUTER



Prof. Dr. Kusri, M.Kom.
NIK. 190302106

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Nor Riduan
NIM : 23.55.1382

Menyatakan bahwa Tesis dengan judul berikut:

ANALISIS PENGARUH PENGATURAN OPTIMASI PADA ALGORITMA XGBOOST UNTUK MEMREDIKSI KESEHATAN MENTAL SISWA SEKOLAH MENENGAH

Dosen Pembimbing Utama: Alva Hendi Muhammad, A.Md., S.T., M.Eng., Ph.D.

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya.
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing.
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini.
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta.
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 07 Januari 2026
Yang Menyatakan,



10000
NOR RIDUAN
23551382
Nor Riduan

HALAMAN PERSEMBAHAN

Alhamdulillahirobbilalamin. Puji syukur kehadiran Allah SWT penulis dapat menjadi pribadi yang berpikir dan berilmu, serta kemudahan yang telah diberikan akhirnya tesis ini dapat terselesaikan. Tesis ini penulis persembahkan untuk:

1. Seluruh keluarga. Almarhum bapak Syahransah, ibu Arbayah, bapak mertua H. Muhammad Mas'ud SH, ibu mertua Hj. Hartati. Untuk istriku Rismawarni dan anak-anakku Nur Tajlina Assyafa'ah dan Maulidina Qurota A'yun terima kasih atas doa dan dukungan motivasinya sehingga saya dapat menyelesaikan pendidikan S2 PJJ Informatika.
2. Alva Hendi Muhammad, S.T., M.Eng., Ph.D sebagai dosen pembimbing, terima kasih telah memberikan bimbingan dan saran sehingga tesis ini dapat terselesaikan.
3. Sahabat dan teman seperjuangan yang selalu memberikan semangat dan dukungan dalam pengerjaan tesis ini.

KATA PENGANTAR

Ilmu bukanlah dengan banyaknya riwayat. Ilmu tidak lain adalah sebuah cahaya yang Allah tempatkan di dalam hati. Cahaya ilmu tidak lelah menerangi kehidupan dengan sinarnya. Atas karunia dan rahmatNya, penulis dapat menyelesaikan tesis dengan judul “ANALISIS PENGARUH PENGATURAN OPTIMASI PADA ALGORITMA XGBOOST UNTUK MEMPREDIKSI KESEHATAN MENTAL SISWA SEKOLAH MENENGAH” salah satu persyaratan untuk memperoleh gelar Magister Komputer dari Program Studi S2 PJJ Informatika Program Pascasarjana Universitas AMIKOM Yogyakarta.

Dalam penyusunan skripsi ini, penulis mengucapkan terima kasih kepada semua pihak yang telah membantu dalam proses penulisan, terutama kepada:

1. Prof. Dr. M. Suyanto, M.M. selaku Rektor Universitas Amikom Yogyakarta
2. Prof. Dr. Kusriani, M.Kom. selaku Direktur Program Pascasarjana Universitas Amikom Yogyakarta
3. Alva Hendi Muhammad, S.T., M.Eng., Ph.D selaku Pembimbing Utama

Semoga apa yang penulis kerjakan diridhoi oleh Allah SWT, karena hanya kepadaNya segala usaha dipasrahkan.

Yogyakarta, 07 Januari 2026

Penulis


DAFTAR ISI

TESIS	i
HALAMAN PERSETUJUAN.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERNYATAAN KEASLIAN TESIS.....	iv
KATA PENGANTAR.....	vi
DAFTAR ISI.....	vii
DAFTAR TABEL.....	ix
DAFTAR GAMBAR.....	x
INTISARI.....	xi
<i>ABSTRACT</i>	xii
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	5
1.3. Batasan Masalah.....	6
1.4. Tujuan Penelitian.....	7
1.5. Manfaat Penelitian.....	8
BAB II TINJAUAN PUSTAKA.....	9
2.1. Tinjauan Pustaka.....	9
2.2. Keaslian Penelitian.....	14
2.3.1. Kesehatan Mental.....	19
2.3.2. Machine learning.....	22
2.3.3. XGBoost Regressor.....	26
2.3.4. Hyperparameter Tuning.....	30
2.3.5. Genetic Algorithm.....	33
2.3.6. Particle Swarm Optimization.....	38
2.3.7. Bayesian Optimization.....	42
2.3.8. Evaluasi Model.....	47
BAB III METODE PENELITIAN.....	52

3.1. Jenis, Sifat dan Pendekatan Penelitian	52
3.2. Metode Pengumpulan Data	53
3.3. Metode Analisis Data	54
3.4. Alur Penelitian.....	55
BAB IV HASIL PENELITIAN DAN PEMBAHASAN	58
4.1. Pengumpulan Data.....	59
4.2. <i>Preprocessing Data</i>	65
4.3. Pemodelan	68
4.3.1. Model Baseline XGBoost Regressor	69
4.3.2. Optimasi Menggunakan <i>Genetic Algorithm</i>	71
4.3.3. Optimasi Menggunakan <i>Particle Swarm Optimization</i>	72
4.3.4. Optimasi Menggunakan Bayesian Optimization	74
4.3.5. Analisis Perbandingan Hasil Pemodelan	75
4.4. Analisis Komparasi	76
BAB V PENUTUP	80
5.1. Kesimpulan	80
5.2. Saran	82
Daftar Pustaka	85
Lampiran	92

DAFTAR TABEL

Tabel 2. 1 Matriks Literatur Review dan Posisi Penelitian.....	14
Tabel 4. 1 Deskripsi atribut dataset dan Raw data.....	60
Tabel 4. 2 Penjelasan Atribut Dataset.....	61
Tabel 4. 3 Perbandingan Hasil Evaluasi Model.....	75



DAFTAR GAMBAR

Gambar 2. 1 Alur Algoritma <i>Genetic Algorithm</i>	37
Gambar 2. 2 Alur <i>Particle Swarm Optimization</i>	41
Gambar 2. 3 Alur <i>Bayesian Optimization</i>	45
Gambar 3. 1 Kerangka Alur Penelitian.....	55
Gambar 4. 1 Korelasi Pearson antara Semua Fitur.....	67



INTISARI

Kesehatan mental merupakan aspek penting dari kesejahteraan manusia yang semakin mendapat perhatian, khususnya pada kalangan remaja. Penelitian ini bertujuan untuk memprediksi kondisi kesehatan mental siswa menggunakan pendekatan regresi berbasis *machine learning* dengan algoritma XGBoost. Untuk meningkatkan performa prediksi, dilakukan optimasi menggunakan tiga metode, yaitu *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization*. Evaluasi performa model dilakukan menggunakan metrik Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Percentage Error (MAPE), dan koefisien determinasi (R^2). Hasil eksperimen menunjukkan bahwa model baseline menghasilkan nilai MSE sebesar 0,8893, RMSE 0,9430, MAPE 23,31%, dan R^2 sebesar 0,3841. Setelah dilakukan optimasi, seluruh metode menunjukkan peningkatan performa model. PSO menghasilkan nilai MSE dan RMSE terendah serta nilai R^2 tertinggi sebesar 0,5135, GA menghasilkan nilai MAPE terendah sebesar 21,89%, sedangkan BO menunjukkan performa yang kompetitif dalam meminimalkan kesalahan prediksi secara relatif. Hasil ini menunjukkan bahwa optimasi secara signifikan meningkatkan performa model prediksi kesehatan mental siswa, namun efektivitasnya bersifat kondisional dan dipengaruhi oleh kesesuaian metode optimasi dengan karakteristik data psikososial yang digunakan.

Kata kunci: Prediksi kesehatan mental, *XGBoost Regressor*, *Genetic Algorithm*, *Particle Swarm Optimization*, *Bayesian Optimization*.

ABSTRACT

Mental health is an essential aspect of human well-being that has increasingly gained attention, particularly among adolescents. This study aims to predict students' mental health conditions using a regression-based machine learning approach with the XGBoost algorithm. To improve predictive performance, hyperparameter optimization was applied using three methods: Genetic Algorithm, Particle Swarm Optimization, and Bayesian Optimization. Model performance was evaluated using Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Percentage Error (MAPE), and the coefficient of determination (R^2). The experimental results show that the baseline model achieved an MSE of 0.8893, RMSE of 0.9430, MAPE of 23.31%, and an R^2 value of 0.3841. After optimization, all methods demonstrated improved performance. PSO produced the lowest MSE and RMSE and the highest R^2 value of 0.5135, GA achieved the lowest MAPE at 21.89%, while BO showed competitive performance in minimizing relative prediction errors. These findings indicate that hyperparameter optimization significantly enhances the performance of mental health prediction models; however, its effectiveness is conditional and depends on the suitability of the optimization method to the characteristics of the psychosocial data used.

Keyword: Mental health prediction, XGBoost Regressor, Genetic Algorithm, Particle Swarm Optimization, Bayesian Optimization.

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Kesehatan mental merupakan salah satu aspek fundamental dari kesejahteraan manusia yang mencakup kondisi emosional, psikologis, dan sosial individu dalam menjalani kehidupan sehari-hari. Meskipun perannya sangat penting, isu kesehatan mental sering kali kurang mendapatkan perhatian yang memadai, khususnya dalam konteks pendidikan. Menurut *World Health Organization* (WHO), lebih dari 264 juta orang di seluruh dunia menderita depresi dan sekitar 284 juta orang mengalami gangguan kecemasan. Kondisi ini tidak hanya berdampak pada kualitas hidup individu, tetapi juga memberikan konsekuensi serius terhadap produktivitas, stabilitas sosial, serta beban ekonomi global (Sniadach et al., 2021). Oleh karena itu, deteksi dini dan pemahaman yang lebih komprehensif terhadap masalah kesehatan mental menjadi kebutuhan mendesak, terutama pada kelompok usia rentan.

Kelompok remaja sekolah menengah merupakan salah satu populasi yang sangat rentan terhadap gangguan kesehatan mental. Pada fase perkembangan ini, individu berada pada masa transisi yang ditandai dengan perubahan biologis, tekanan akademik, tuntutan sosial, serta pembentukan identitas diri. Kondisi tersebut menjadikan remaja lebih mudah mengalami stres, kecemasan, dan gangguan emosional lainnya. Situasi ini semakin diperparah oleh dampak pandemi COVID-19 yang mengubah pola pembelajaran, interaksi sosial, serta rutinitas

kehidupan remaja secara drastis. Data dari *Centers for Disease Control and Prevention* (CDC) tahun 2021 menunjukkan bahwa lebih dari sepertiga (37%) siswa sekolah menengah di Amerika Serikat melaporkan kondisi kesehatan mental yang buruk selama pandemi, dengan 44% di antaranya mengalami perasaan sedih atau putus asa secara terus-menerus selama satu tahun terakhir. Selain itu, lebih dari separuh siswa (55%) melaporkan mengalami pelecehan emosional di lingkungan rumah, bahkan 11% di antaranya mengalami kekerasan fisik (Jones et al., 2022). Temuan ini menegaskan bahwa kesehatan mental siswa sekolah menengah merupakan isu serius yang memerlukan perhatian lintas sektor.

Fenomena serupa juga ditemukan di berbagai negara berkembang. Studi di Nepal menunjukkan bahwa siswa sekolah menengah sangat rentan mengalami depresi, kecemasan, dan stres akibat tekanan akademik, latar belakang pendidikan orang tua, paparan cyberbullying, serta perbedaan jenis sekolah (negeri atau swasta). Selain faktor internal dan lingkungan sekolah, keterbatasan akses terhadap layanan psikologis serta stigma sosial terhadap gangguan kesehatan mental menjadi hambatan utama bagi siswa untuk memperoleh bantuan yang memadai (Karki et al., 2022). Kondisi ini menunjukkan bahwa permasalahan kesehatan mental pada remaja sekolah menengah bersifat kompleks dan multifaktorial, melibatkan interaksi antara faktor individu, keluarga, sekolah, dan masyarakat (Venrooij, 2024). Oleh karena itu, pendekatan yang digunakan untuk memahami permasalahan ini tidak dapat bersifat tunggal atau parsial.

Sifat multifaktorial dari kesehatan mental remaja menyebabkan kesulitan dalam mengidentifikasi faktor-faktor dominan yang paling berpengaruh terhadap

kondisi psikologis siswa. (Patel et al., 2008) menekankan bahwa kesehatan mental remaja dipengaruhi oleh kombinasi faktor biologis, psikologis, sosial, dan budaya yang saling berinteraksi secara dinamis. Pendekatan konvensional yang hanya mengandalkan observasi subjektif atau analisis deskriptif sering kali tidak mampu menangkap pola hubungan yang kompleks antar variabel tersebut. Selain itu, pendekatan komprehensif membutuhkan keterlibatan banyak pihak, sumber daya yang besar, serta penyesuaian dengan konteks geografis dan budaya tertentu. Oleh karena itu, diperlukan pendekatan analitik berbasis data yang mampu mengidentifikasi pola-pola tersembunyi secara lebih objektif dan sistematis.

Seiring dengan perkembangan teknologi informasi dan kecerdasan buatan, *machine learning* menawarkan peluang baru dalam analisis dan prediksi kesehatan mental. Pendekatan *machine learning* memungkinkan pengolahan data dalam jumlah besar serta pemodelan hubungan nonlinier antar variabel yang sulit ditangkap oleh metode statistik konvensional. Berbagai studi menunjukkan bahwa *machine learning* mampu menganalisis data survei, catatan kesehatan, maupun data perilaku untuk mengidentifikasi risiko depresi, kecemasan, dan stres secara lebih akurat (Gil et al., 2022). Penelitian yang dilakukan oleh (Chung & Teo, 2023) menunjukkan bahwa algoritma berbasis *ensemble*, khususnya *Gradient Boosting*, memiliki tingkat akurasi tertinggi dalam prediksi kondisi kesehatan mental dibandingkan algoritma lain.

Salah satu algoritma *ensemble* yang banyak digunakan adalah *Extreme Gradient Boosting* (XGBoost) Regressor, yang dikembangkan berdasarkan prinsip *Gradient Boosting Decision Tree* (GBDT). XGBoost dikenal memiliki keunggulan

dalam menangani data nonlinier, interaksi antar fitur yang kompleks, serta mekanisme regularisasi yang mampu mengurangi risiko *overfitting*. Karakteristik ini menjadikan XGBoost Regressor sebagai algoritma yang potensial untuk digunakan dalam prediksi kesehatan mental siswa sekolah menengah, yang datanya cenderung heterogen, subjektif, dan dipengaruhi oleh berbagai faktor psikososial. Namun demikian, performa XGBoost Regressor sangat bergantung pada pengaturan, seperti *learning rate*, *max depth*, dan jumlah estimator. Pemilihan nilai yang kurang tepat dapat menyebabkan model menghasilkan prediksi yang tidak optimal, meskipun algoritma yang digunakan sudah canggih.

Untuk mengatasi permasalahan tersebut, berbagai metode optimasi telah dikembangkan. *Genetic Algorithm* dan *Particle Swarm Optimization* merupakan metode optimasi metaheuristik berbasis populasi yang meniru proses alam, seperti evolusi biologis dan perilaku sosial. Sementara itu, *Bayesian Optimization* menggunakan pendekatan probabilistik untuk mengeksplorasi ruang pencarian secara lebih efisien dengan menyeimbangkan eksplorasi dan eksploitasi. Meskipun ketiga metode ini telah banyak diterapkan dalam berbagai bidang *machine learning*, penelitian yang secara khusus membandingkan efektivitas *Genetic Algorithm* dan *Particle Swarm Optimization* dalam optimasi *XGBoost Regressor* pada domain kesehatan mental siswa sekolah menengah masih sangat terbatas.

Berdasarkan kondisi tersebut, penelitian ini difokuskan pada analisis dan perbandingan tiga metode optimasi, yaitu *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization*, dalam meningkatkan kinerja *XGBoost Regressor* untuk memprediksi kesehatan mental siswa sekolah menengah.

Penelitian ini tidak hanya bertujuan untuk memperoleh model dengan tingkat akurasi yang lebih baik, tetapi juga untuk memahami bagaimana karakteristik data psikososial memengaruhi efektivitas masing-masing metode optimasi. Dengan demikian, hasil penelitian diharapkan dapat memberikan kontribusi akademik dalam pengembangan metode prediksi kesehatan mental berbasis *machine learning*, sekaligus memberikan manfaat praktis sebagai dasar pengembangan sistem pendukung keputusan dalam bidang pendidikan dan kesehatan remaja.

1.2. Rumusan Masalah

Berdasarkan uraian latar belakang yang telah dipaparkan, permasalahan utama dalam penelitian ini berkaitan dengan bagaimana pemanfaatan metode optimasi dapat meningkatkan kinerja model prediksi kesehatan mental siswa sekolah menengah. Oleh karena itu, rumusan masalah dalam penelitian ini dirumuskan sebagai berikut:

- a. Bagaimana pengaruh optimasi menggunakan *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization* terhadap peningkatan kinerja model XGBoost Regressor dalam memprediksi kesehatan mental siswa sekolah menengah?
- b. Metode optimasi manakah yang paling efektif dalam meningkatkan performa prediksi XGBoost Regressor berdasarkan karakteristik data kesehatan mental siswa sekolah menengah?

- c. Bagaimana hubungan antara indikator kesehatan mental siswa dengan tingkat kesalahan prediksi model, serta apa implikasinya terhadap performa dan stabilitas model secara keseluruhan?

1.3. Batasan Masalah

Untuk menjaga fokus penelitian dan membatasi ruang lingkup pembahasan, penelitian ini memiliki beberapa batasan sebagai berikut:

- a. Data yang digunakan dalam penelitian ini merupakan data tingkat kesejahteraan emosional siswa sekolah menengah yang diperoleh dari dataset publik Kaggle, yaitu *High School Emotional Well-Being Dataset* (<https://www.kaggle.com/datasets/jeffreyxshen/high-school-emotional-well-being>)
- b. Penelitian ini hanya berfokus pada prediksi kondisi kesehatan mental siswa sekolah menengah berbasis data survei, dan tidak mencakup intervensi psikologis, diagnosis klinis, maupun penanganan medis secara langsung.
- c. Algoritma utama yang digunakan dalam penelitian ini adalah XGBoost Regressor, dengan proses optimasi dilakukan menggunakan tiga metode, yaitu *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization*.
- d. Platform yang digunakan dalam proses pengolahan data dan pembangunan model adalah *Google Colaboratory (Google Colab)*, sehingga penelitian ini tidak mencakup implementasi lanjutan dalam bentuk aplikasi end-user atau sistem produksi.

- e. Evaluasi kinerja model difokuskan pada metrik regresi, yaitu *Mean Squared Error (MSE)*, *Root Mean Squared Error (RMSE)*, *Mean Absolute Percentage Error (MAPE)*, serta koefisien determinasi (R^2). Aspek lain seperti interpretabilitas model dan analisis kausal tidak menjadi fokus utama penelitian ini.

1.4. Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut:

- a. Menganalisis pengaruh optimasi terhadap peningkatan kinerja model XGBoost Regressor dalam memprediksi kesehatan mental siswa sekolah menengah.
- b. Membandingkan efektivitas metode optimasi *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization* dalam meningkatkan performa prediksi berdasarkan karakteristik data kesehatan mental siswa.
- c. Mengidentifikasi hubungan antara indikator kesehatan mental siswa dengan tingkat kesalahan prediksi model untuk menjelaskan faktor-faktor dominan yang memengaruhi naik-turunnya performa model.
- d. Menentukan kondisi data di mana masing-masing metode optimasi bekerja secara optimal dalam meningkatkan akurasi dan stabilitas model prediksi.
- e. Mengevaluasi relevansi penggunaan metrik MSE, RMSE, MAPE, dan R^2 dalam konteks prediksi kesehatan mental siswa, serta menginterpretasikan makna praktis dari nilai kesalahan yang dihasilkan.

- f. Merumuskan implikasi hasil prediksi model sebagai dasar konseptual bagi pengembangan sistem pendukung keputusan dalam lingkungan pendidikan.

1.5. Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

- a. Memberikan kontribusi dalam pengembangan kajian ilmu *machine learning*, khususnya pada penerapan algoritma XGBoost Regressor dengan optimasi untuk prediksi kesehatan mental berbasis data psikososial.
- b. Menambah literatur ilmiah terkait perbandingan metode optimasi, yaitu *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization*, dalam meningkatkan performa model prediksi berbasis *ensemble learning*.
- c. Menjadi referensi akademik bagi peneliti, pendidik, dan praktisi yang tertarik mengkaji prediksi kesehatan mental siswa, serta sebagai dasar konseptual pengembangan sistem pendukung keputusan di lingkungan pendidikan.

BAB II

TINJAUAN PUSTAKA

2.1. Tinjauan Pustaka

Penelitian mengenai prediksi kesehatan mental dengan pendekatan *machine learning* telah mengalami perkembangan yang signifikan dalam beberapa tahun terakhir, seiring dengan meningkatnya ketersediaan data serta kemajuan algoritma kecerdasan buatan. Berbagai model prediktif telah diterapkan untuk mengidentifikasi risiko gangguan mental seperti depresi, kecemasan, dan stres, baik pada populasi umum maupun kelompok usia tertentu. Meskipun demikian, hasil yang dilaporkan oleh penelitian-penelitian tersebut menunjukkan variasi performa yang cukup besar, yang mengindikasikan bahwa keberhasilan model sangat dipengaruhi oleh karakteristik data, algoritma yang digunakan, serta strategi optimasi yang diterapkan.

Studi yang dilakukan oleh (Amirhosseini et al., 2024) menunjukkan bahwa penggunaan XGBoost Regressor yang dikombinasikan dengan optimasi *Genetic Algorithm* mampu meningkatkan akurasi prediksi tingkat depresi secara signifikan dengan nilai R^2 mencapai 0,9. Hasil ini menegaskan potensi besar *Genetic Algorithm* dalam menemukan kombinasi yang optimal sehingga mampu menekan kesalahan prediksi dan meningkatkan stabilitas model. Namun demikian, penelitian tersebut menggunakan dataset kesehatan umum (NHANES) yang bersifat klinis dan relatif homogen, sehingga hasil yang diperoleh belum tentu dapat digeneralisasikan pada populasi siswa sekolah menengah yang memiliki karakteristik psikososial

lebih kompleks dan subjektif. Perbedaan konteks data ini menunjukkan adanya perbedaan persepsi terhadap makna performa model yang baik, di mana nilai R^2 tinggi pada data klinis belum tentu mudah dicapai pada data survei pendidikan.

Penelitian lain yang dilakukan oleh (Ayodele et al., 2024) membandingkan beberapa algoritma *machine learning*, antara lain Linear Regression, *Support Vector Machine*, *Random Forest*, dan XGBoost, dalam memprediksi tingkat depresi. Hasil penelitian menunjukkan bahwa *Random Forest* memberikan performa terbaik dengan nilai MSE sebesar 1,73 dan R^2 sebesar 0,93, sementara XGBoost berada pada posisi kedua. Temuan ini menyoroti pentingnya pemilihan algoritma yang tepat dalam konteks prediksi kesehatan mental. Namun, penelitian tersebut belum memberikan perhatian khusus pada proses optimasi, sehingga performa XGBoost yang diperoleh masih bersifat *baseline*. Hal ini mengindikasikan bahwa potensi XGBoost belum dimanfaatkan secara optimal dan masih terbuka ruang peningkatan performa melalui teknik tuning yang lebih sistematis.

Penelitian juga dilakukan oleh (Riosatria et al., 2024) memprediksi tren kesehatan mental menggunakan *Multiple Linear Regression* dan *Neural Network Backpropagation*. Hasil penelitian menunjukkan bahwa *Neural Network* menghasilkan performa yang lebih baik dengan nilai MAE sebesar 111,39 dan MAPE sebesar 1,77%. Meskipun demikian, penelitian ini menggunakan dataset yang sangat terbatas, yaitu hanya 60 data, sehingga risiko *overfitting* menjadi tinggi dan kemampuan generalisasi model menjadi lemah. Kondisi ini menunjukkan bahwa capaian akurasi yang tinggi tidak selalu mencerminkan performa model

yang stabil, terutama ketika diterapkan pada dataset dengan ukuran kecil dan variasi data yang rendah.

Penelitian yang dilakukan oleh (Hossain et al., 2024) membandingkan Linear Regression, *Random Forest*, dan XGBoost Regressor dalam analisis faktor penyebab kematian yang berkaitan dengan kondisi kesehatan mental. Dalam penelitian tersebut, XGBoost Regressor menunjukkan performa terbaik dengan nilai MAE sebesar 83 dan R^2 sebesar 0,552. Namun, nilai R^2 yang relatif moderat menunjukkan bahwa model masih memiliki keterbatasan dalam menjelaskan variasi data secara menyeluruh. Temuan ini mengindikasikan bahwa meskipun XGBoost unggul dibandingkan algoritma lain, proses optimasi yang lebih mendalam masih diperlukan untuk meningkatkan kinerja model, khususnya pada data yang kompleks dan multidimensional.

Penelitian oleh (Shen, 2023) secara khusus menyoroti konteks siswa sekolah menengah dengan mengembangkan dataset kesejahteraan emosional siswa SMA. Faktor-faktor seperti durasi tidur, kepuasan keluarga, dan tingkat kesepian terbukti memiliki pengaruh signifikan terhadap kesehatan mental siswa. Namun, model yang digunakan dalam penelitian tersebut terbatas pada *Neural Network* dan Regresi Linier, dengan capaian performa yang tergolong sedang ($R^2 \approx 0,51$). Hasil ini menunjukkan bahwa meskipun faktor-faktor psikososial utama telah berhasil diidentifikasi, masih terdapat keterbatasan pada kemampuan model dalam menangkap hubungan nonlinier yang kompleks. Oleh karena itu, eksplorasi algoritma *ensemble* yang lebih kuat seperti XGBoost dengan optimasi menjadi peluang penelitian yang relevan.

Studi lain, seperti (Mullick et al., 2022) dan (Gupta et al., 2022), juga menegaskan keunggulan algoritma XGBoost dibandingkan model lain dalam konteks prediksi depresi remaja menggunakan data wearable serta analisis stres tenaga kesehatan. Meskipun hasil yang diperoleh cukup menjanjikan, penelitian-penelitian tersebut umumnya berfokus pada pemilihan algoritma terbaik dan belum melakukan perbandingan metode optimasi secara sistematis. Akibatnya, kontribusi masing-masing metode optimasi terhadap peningkatan performa model belum dapat dievaluasi secara komprehensif.

Beberapa penelitian terdahulu telah mengeksplorasi optimasi berbasis *Genetic Algorithm*, seperti yang dilakukan oleh (Shahvaroughi Farahani & Esfahani, 2022) (Kaliappan et al., 2021), menunjukkan bahwa GA mampu meningkatkan akurasi model prediksi secara signifikan. Namun demikian, penggunaan metode optimasi lain seperti *Particle Swarm Optimization* dan *Bayesian Optimization* masih relatif jarang dikaji, khususnya dalam domain kesehatan mental. Padahal, kedua metode tersebut memiliki karakteristik pencarian yang berbeda dan berpotensi memberikan performa yang lebih stabil atau efisien tergantung pada karakteristik data yang digunakan.

Berdasarkan tinjauan terhadap penelitian-penelitian terdahulu tersebut, dapat disimpulkan bahwa XGBoost Regressor memiliki potensi yang kuat dalam prediksi kesehatan mental, namun performanya sangat bergantung pada pengaturan yang digunakan. Sebagian besar penelitian sebelumnya lebih menitikberatkan pada penggunaan *Genetic Algorithm* sebagai metode optimasi, sementara perbandingan dengan metode lain seperti *Particle Swarm Optimization* dan *Bayesian*

Optimization masih sangat terbatas. Selain itu, terdapat perbedaan persepsi dalam menilai keberhasilan model, di mana sebagian penelitian menekankan capaian nilai R^2 yang tinggi, sementara penelitian lain menyoroiti stabilitas dan kemampuan generalisasi model pada data yang kompleks dan subjektif.

Dengan demikian, terdapat research gap yang jelas, yaitu perlunya penelitian yang secara khusus membandingkan efektivitas *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization* dalam melakukan tuning pada XGBoost Regressor untuk prediksi kesehatan mental siswa sekolah menengah. Penelitian semacam ini diharapkan mampu memberikan pemahaman yang lebih komprehensif mengenai metode optimasi yang paling sesuai dengan karakteristik data psikososial, serta memberikan kontribusi metodologis dan praktis dalam pengembangan model prediksi kesehatan mental di lingkungan pendidikan

2.2. Keaslian Penelitian

Tabel 2.1 Matriks Literatur Review dan Posisi Penelitian

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Prediction of Depression Severity and Personalised Risk Factors Using <i>Machine learning</i> on Multimodal Data	Mohammad Hossein Amirhosseini, Adefemi Lawrence Ayodele, Amin Karami. Brain Sciences, MDPI. 2024	Memprediksi tingkat depresi menggunakan data multimodal (NHANES) dengan optimasi XGBoost Regressor menggunakan <i>Genetic Algorithm</i> .	XGBoost + GA memberikan performa lebih baik dibanding LR atau RF, dengan $R^2 = 0.9$.	Dataset terbatas pada NHANES, perlu validasi pada dataset lain untuk menguji generalisasi.	Penelitian ini menggunakan GA untuk tuning XGBoost, sedangkan penelitian selanjutnya membandingkan GA, PSO, dan Bayesian Optimization.
2	Prediction of Depression Severity and Personalised Risk Factors Using <i>Machine learning</i> on Multimodal Data	Adefemi Ayodele, Adedotun Adetunla, Esther Akinlabi. iJOE. 2024	Mengembangkan model prediksi depresi menggunakan LR, SVM, LASSO, XGBoost, dan RF pada dataset NHANES.	RF ($R^2 = 0.93$) dan XGBoost ($R^2 = 0.91$) lebih unggul dibandingkan LR, SVM, dan LASSO.	Belum ada optimasi, model masih baseline.	Penelitian selanjutnya melakukan tuning secara sistematis untuk meningkatkan performa XGBoost.
3	Enhancing Mental Illness Predictions Analyzing Trends Using Multiple Linear Regression and <i>Neural Network Backpropagation</i>	Riosatria, Hairani Hairani, Anthony Anggrawan, Moch. Syahrir. <i>International Journal of Engineering and Computer Science</i>	Membandingkan prediksi kesehatan mental dengan Multiple Linear Regression dan <i>Neural Network Backpropagation</i> .	NN lebih baik ($MAE = 111.39$, $MAPE = 1.77\%$) dibandingkan MLR ($MAE = 115.24$, $MAPE = 1.83\%$).	Dataset sangat kecil (60 data), rawan <i>overfitting</i> .	Dataset yang digunakan 468 data poin .

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
		<i>Applications</i> (IJECSA). 2024				
4	Analyzing Trends and Determinants of Leading Causes of Death in the USA: A Data-Driven Approach	Saddam Hossain, Mohammed Nazmul Islam Miah, MD Sohel Rana, Md Sazzad Hossain, Proshanta Kumar Bhowmik, Md Khalilur Rahman, Rabeya akter. TAJMSPR. 2024	Menganalisis faktor penyebab kematian (termasuk kondisi mental) menggunakan LR, RF, dan XGBoost.	XGBoost terbaik ($R^2 = 0.552$), lebih unggul dibandingkan LR dan RF.	Belum menerapkan optimasi.	Penelitian ini fokus pada kesehatan masyarakat umum, penelitian selanjutnya fokus pada kesehatan mental siswa dengan optimasi XGBoost.
5	High School Emotional Well-Being: Identifying Factors And Creating A Working Model For Prediction	Yinchu Shen, Journal of Student Research. 2023	Membuat model prediksi kesehatan mental siswa SMA dengan <i>Neural Network</i> dan Regresi Linier.	<i>NN ($R^2 = 0.5176$) sedikit lebih baik dari Regresi Linier ($R^2 = 0.5174$).</i>	Model sederhana, belum membandingkan algoritma optimasi.	Penelitian ini menggunakan NN & RL, sementara pada penelitian ini menggunakan XGBoost + optimasi GA, PSO, dan BO pada dataset yang sama.
6	Predicting Depression in Adolescents Using Mobile and Wearable Sensors: Multimodal	Tahsin Mulliek, Ana Radovic, Sam Shaaban, Afsaneh	Memprediksi skor depresi (PHQ-9) menggunakan data ponsel & wearable	RF (MAE = 2.42) terbaik, diikuti XGBoost (MAE = 2.51).	Dataset kecil (55 remaja), terbatas pada sensor spesifik.	Penelitian ini berbasis sensor, sedangkan penelitian selanjutnya spesifik.

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	<i>Machine learning</i> -Based Exploratory Study	Doryah, JMIR, 2022	dengan RF, XGBoost, AdaBoost, LR, KNN.			menggunakan data survei publik (Kaggle).

Tabel 2.2 Perbandingan Penelitian Terdahulu dengan Penelitian Ini

No	Aspek Perbandingan	Penelitian Terdahulu	Penelitian Ini
1	Domain Penelitian	Umumnya berfokus pada prediksi kesehatan mental secara umum atau aspek psikologis tertentu, dengan konteks pendidikan yang masih terbatas	Secara khusus berfokus pada prediksi kesehatan mental siswa sekolah menengah dalam konteks lingkungan pendidikan
2	Jenis Data	Data psikologis atau survei dengan jumlah variabel terbatas, sering kali bersifat linier	Data kesejahteraan emosional siswa yang bersifat psikososial, multidimensional, dan nonlinier
3	Pendekatan Metodologis	Didominasi metode statistik klasik atau satu algoritma machine learning tanpa optimasi lanjutan	Pendekatan machine learning eksperimental dengan analisis komparatif antar metode optimasi
4	Algoritma Utama	Regresi linier, SVM, Random Forest, atau Neural Network	XGBoost Regressor sebagai algoritma utama
5	Optimasi	Menggunakan grid search atau random search, atau tanpa optimasi	Menggunakan tiga metode optimasi : Genetic Algorithm, Particle Swarm Optimization, dan Bayesian Optimization
6	Fokus Evaluasi	Menitikberatkan pada nilai akurasi atau error secara tunggal	Menggunakan evaluasi komprehensif meliputi MSE, RMSE, MAPE, dan koefisien determinasi (R^2)
7	Analisis Perbandingan	Perbandingan model atau metode masih terbatas dan bersifat deskriptif	Analisis komparatif mendalam antara model baseline dan model hasil optimasi

No	Aspek Perbandingan	Penelitian Terdahulu	Penelitian Ini
8	Interpretasi Hasil	Berorientasi pada capaian performa numerik	Mengaitkan performa model dengan karakteristik data psikososial dan konteks pendidikan
9	Kontribusi Ilmiah	Menunjukkan efektivitas algoritma tertentu pada domain kesehatan mental	Memberikan kerangka analitis terpadu antara algoritma, metode optimasi, dan karakteristik data kesehatan mental siswa
10	Implikasi Praktis	Sebagian besar masih bersifat konseptual atau teknis	Berpotensi dikembangkan sebagai sistem pendukung keputusan atau alat deteksi dini di lingkungan sekolah

Berdasarkan Tabel 2.2, dapat dilihat bahwa penelitian ini memiliki perbedaan mendasar dibandingkan dengan penelitian-penelitian terdahulu, baik dari sisi pendekatan metodologis, fokus analisis, maupun kontribusi ilmiahnya. Penelitian terdahulu umumnya masih menitikberatkan pada penggunaan metode statistik konvensional atau satu algoritma machine learning tanpa optimasi yang komprehensif, sehingga kemampuan model dalam menangkap kompleksitas hubungan antar variabel psikososial masih terbatas. Selain itu, konteks pendidikan sering kali hanya dijadikan latar belakang, tanpa pembahasan mendalam mengenai implikasi hasil prediksi terhadap lingkungan sekolah dan pengambilan keputusan edukatif.

Sebaliknya, penelitian ini secara eksplisit mengadopsi pendekatan machine learning eksperimental dengan menjadikan *XGBoost Regressor* sebagai algoritma utama dan mengombinasikannya dengan tiga metode optimasi yang berbeda, yaitu *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization*. Perbandingan dilakukan secara sistematis antara model baseline dan model hasil optimasi menggunakan berbagai metrik evaluasi, termasuk koefisien determinasi (R^2), sehingga penilaian kinerja model tidak hanya berfokus pada besarnya kesalahan prediksi, tetapi juga pada kemampuan model dalam menjelaskan variasi data kesehatan mental siswa. Pendekatan ini memungkinkan analisis yang lebih menyeluruh terhadap performa, stabilitas, dan relevansi model dalam konteks data psikososial yang bersifat nonlinier dan subjektif.

Dengan demikian, penelitian ini tidak hanya mereplikasi pendekatan yang telah ada, tetapi memperluas kajian sebelumnya dengan menghadirkan kerangka analitis yang mengaitkan algoritma, metode optimasi, dan karakteristik data kesehatan mental siswa secara terpadu. Kontribusi penelitian ini terletak pada penguatan aspek komparatif dan kontekstual, sehingga hasil yang diperoleh tidak hanya bernilai secara teknis, tetapi juga memiliki potensi aplikatif sebagai dasar pengembangan sistem pendukung keputusan dan deteksi dini kesehatan mental siswa di lingkungan sekolah.

2.3. Landasan Teori

2.3.1. Kesehatan Mental

Peserta didik pada jenjang sekolah menengah berada pada fase perkembangan yang rentan terhadap berbagai tekanan, baik dari aspek akademik, sosial, maupun emosional. Tuntutan pencapaian prestasi akademik, dinamika hubungan dengan teman sebaya, serta proses pencarian identitas diri sering kali menjadi sumber stres yang berkelanjutan. Kondisi tersebut dapat berdampak langsung pada kesejahteraan mental siswa apabila tidak diimbangi dengan dukungan psikologis dan lingkungan yang kondusif (Liu et al., 2022). Oleh karena itu, kesehatan mental siswa menjadi aspek krusial yang tidak dapat dipisahkan dari proses pendidikan secara keseluruhan.

Secara konseptual, kesehatan mental dapat dipahami sebagai kondisi psikologis, emosional, dan sosial yang memengaruhi cara individu berpikir, merasakan emosi, mengambil keputusan, serta berperilaku dalam kehidupan sehari-hari (Kittleson, 2019). Definisi ini menegaskan bahwa kesehatan mental tidak hanya

berkaitan dengan ketiadaan gangguan psikologis, tetapi juga mencakup kemampuan individu untuk berfungsi secara adaptif dalam menghadapi tantangan hidup. Dalam konteks pendidikan, kesehatan mental yang baik menjadi fondasi penting bagi perkembangan akademik dan sosial siswa, karena memengaruhi konsentrasi belajar, motivasi, serta kemampuan membangun hubungan interpersonal yang sehat.

Indikator kesehatan mental yang positif pada siswa sekolah menengah mencakup kemampuan mengelola stres secara efektif, menjalin hubungan sosial yang suportif, mengambil keputusan yang rasional, serta beradaptasi terhadap perubahan dan tekanan lingkungan (McKee & Breslin, 2022). Siswa dengan kondisi kesehatan mental yang baik cenderung memiliki resiliensi yang lebih tinggi, mampu mengatasi kegagalan akademik, dan menunjukkan perilaku prososial di lingkungan sekolah. Sebaliknya, ketika kesehatan mental terganggu, siswa berisiko mengalami berbagai permasalahan serius yang berdampak jangka pendek maupun jangka panjang.

Gangguan kesehatan mental pada siswa dapat memanifestasikan diri dalam berbagai bentuk, seperti penurunan prestasi akademik, kesulitan berkonsentrasi, menarik diri dari lingkungan sosial, hingga munculnya gangguan psikologis seperti depresi, kecemasan, dan gangguan makan (Kittleson, 2019). Faktor risiko yang memperburuk kondisi ini antara lain tekanan akademik yang berlebihan, konflik keluarga, kurangnya dukungan sosial, serta paparan lingkungan yang tidak kondusif. Apabila tidak ditangani secara tepat, gangguan kesehatan mental pada masa remaja berpotensi berlanjut hingga usia dewasa dan memengaruhi kualitas hidup individu secara menyeluruh.

Data empiris menunjukkan bahwa permasalahan kesehatan mental pada remaja merupakan isu yang semakin mengkhawatirkan. Berdasarkan hasil survei *Indonesia National Adolescent Mental Health Survey (I-NAMHS)* tahun 2022, sekitar 33% remaja usia 10–17 tahun di Indonesia mengalami masalah kesehatan mental, dan sekitar 5% di antaranya atau setara dengan 2,45 juta remaja memenuhi kriteria diagnosis gangguan mental dalam kurun waktu satu tahun terakhir (Wahdi et al., 2023). Temuan ini menunjukkan bahwa kesehatan mental remaja bukan lagi permasalahan individual, melainkan persoalan kesehatan masyarakat yang memerlukan penanganan sistematis dan berkelanjutan.

Dalam konteks sekolah, penanganan kesehatan mental siswa idealnya dilakukan melalui pendekatan multilevel yang melibatkan berbagai pemangku kepentingan. Pendekatan ini mencakup peningkatan literasi kesehatan mental di kalangan siswa dan guru, pengurangan stigma terhadap gangguan psikologis, serta penguatan hubungan antara siswa, keluarga, dan tenaga profesional seperti konselor atau psikolog sekolah (Liu et al., 2022). Namun demikian, implementasi pendekatan tersebut sering kali menghadapi keterbatasan sumber daya, baik dari sisi jumlah tenaga profesional, waktu, maupun kapasitas institusi pendidikan.

Selain itu, penilaian kondisi kesehatan mental siswa umumnya masih bergantung pada observasi subjektif, wawancara, atau kuesioner yang dianalisis secara deskriptif. Pendekatan ini memiliki keterbatasan dalam menangkap kompleksitas interaksi antar faktor psikososial yang memengaruhi kesehatan mental. Data kesehatan mental siswa juga bersifat dinamis, subjektif, dan dipengaruhi oleh konteks sosial serta budaya, sehingga sulit dianalisis secara linier dan sederhana.

Keterbatasan tersebut membuka peluang bagi pemanfaatan pendekatan berbasis data untuk melengkapi metode konvensional yang sudah ada.

Dalam konteks inilah, pendekatan prediksi berbasis *machine learning* menjadi relevan sebagai alat bantu untuk memahami pola kesehatan mental siswa secara lebih objektif. Dengan memanfaatkan data psikososial siswa, model prediktif dapat membantu mengidentifikasi hubungan kompleks antar variabel yang berkontribusi terhadap kondisi kesehatan mental. Meskipun demikian, penting untuk ditekankan bahwa pendekatan prediksi ini tidak dimaksudkan untuk menggantikan peran tenaga profesional atau diagnosis klinis, melainkan sebagai sistem pendukung keputusan (*decision support system*) yang membantu proses deteksi dini dan perencanaan intervensi di lingkungan sekolah.

Dengan demikian, landasan teori mengenai kesehatan mental dalam penelitian ini menjadi pijakan penting untuk memahami konteks domain yang diteliti. Pemahaman yang komprehensif mengenai karakteristik kesehatan mental siswa sekolah menengah, faktor risiko yang memengaruhinya, serta keterbatasan pendekatan konvensional menjadi dasar rasional bagi penggunaan model prediksi berbasis *machine learning*. Landasan ini juga memperkuat relevansi penelitian dalam mengkaji efektivitas optimasi pada model XGBoost Regressor untuk prediksi kesehatan mental siswa sekolah menengah secara lebih akurat dan kontekstual.

2.3.2. Machine learning

Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence/AI*) telah membuka peluang baru dalam berbagai bidang, termasuk bidang kesehatan dan

kesehatan mental (Thakkar et al., 2024). AI memungkinkan pemanfaatan data dalam jumlah besar untuk menghasilkan informasi dan pengetahuan yang sebelumnya sulit diperoleh melalui pendekatan konvensional. Salah satu cabang AI yang paling banyak digunakan adalah *machine learning*, yaitu pendekatan komputasional yang memungkinkan sistem komputer untuk belajar dari data, mengidentifikasi pola, dan membuat prediksi tanpa harus diprogram secara eksplisit untuk setiap kondisi tertentu (Bintoro et al., 2024). Pendekatan ini menjadi semakin relevan seiring meningkatnya kompleksitas permasalahan kesehatan mental yang melibatkan banyak variabel dan interaksi nonlinier.

Dalam konteks kesehatan mental, *machine learning* memiliki peran penting dalam membantu mengidentifikasi pola-pola perilaku, gejala psikologis, serta faktor risiko yang berhubungan dengan gangguan mental. Data yang digunakan dapat berasal dari berbagai sumber, seperti survei kesejahteraan emosional, catatan kesehatan, data perilaku, maupun informasi sosial-demografis siswa. Dengan memanfaatkan data tersebut, model *machine learning* mampu melakukan analisis prediktif yang lebih objektif dan berbasis bukti dibandingkan dengan metode konvensional yang cenderung deskriptif dan bergantung pada interpretasi subjektif (Khoo et al., 2024) (Bokonda et al., 2020). Hal ini menjadikan *machine learning* sebagai alat bantu yang potensial dalam mendukung proses pengambilan keputusan di lingkungan pendidikan.

Berbagai algoritma *machine learning* telah diterapkan dalam penelitian kesehatan mental, baik untuk tugas klasifikasi maupun regresi. Algoritma seperti *Decision Tree*, *Random Forest*, *Support Vector Machine*, *Gradient Boosting*, dan

Neural Network telah terbukti mampu memberikan performa yang kompetitif dalam memodelkan data kesehatan yang kompleks. Namun, karakteristik data kesehatan mental yang cenderung heterogen, mengandung *noise*, serta memiliki hubungan nonlinier antar variabel menuntut penggunaan algoritma yang memiliki kemampuan generalisasi yang baik dan tahan terhadap *overfitting*. Oleh karena itu, pendekatan *ensemble learning*, khususnya algoritma berbasis *boosting*, semakin banyak digunakan dalam penelitian kesehatan mental.

Salah satu algoritma *ensemble* yang banyak mendapat perhatian adalah XGBoost (*Extreme Gradient Boosting*). XGBoost merupakan pengembangan dari metode *Gradient Boosting Decision Tree* yang dirancang untuk menghasilkan performa prediksi tinggi dengan efisiensi komputasi yang lebih baik. Keunggulan utama XGBoost terletak pada kemampuannya menangani data nonlinier, memodelkan interaksi kompleks antar fitur, serta menerapkan mekanisme regularisasi untuk mengontrol kompleksitas model (Putra et al., 2024). Karakteristik ini menjadikan XGBoost sangat sesuai untuk digunakan dalam prediksi kesehatan mental, di mana variabel akademik, sosial, dan emosional saling berinteraksi secara dinamis dan tidak selalu mengikuti pola linier.

Dalam penelitian kesehatan mental, penggunaan XGBoost memungkinkan pemodelan hubungan antara faktor-faktor seperti tekanan akademik, dukungan sosial, kebiasaan tidur, dan kondisi emosional siswa dengan tingkat kesehatan mental secara lebih presisi. Model regresi berbasis XGBoost dapat menghasilkan estimasi kontinu yang menggambarkan tingkat risiko atau kondisi kesehatan mental siswa, sehingga lebih fleksibel dibandingkan pendekatan klasifikasi biner yang cenderung

menyederhanakan kondisi psikologis menjadi kategori tertentu (Zhai et al., 2025). Pendekatan regresi ini sejalan dengan sifat kesehatan mental yang berada pada spektrum kontinu, bukan sekadar kondisi “sehat” atau “tidak sehat”.

Meskipun demikian, performa algoritma *machine learning*, termasuk XGBoost, sangat dipengaruhi oleh pengaturan yang digunakan dalam proses pelatihan model. Hyperparameter seperti *learning rate*, *max depth*, jumlah estimator, dan subsample menentukan tingkat kompleksitas model, kecepatan pembelajaran, serta kemampuan generalisasi terhadap data baru. Pemilihan nilai yang kurang tepat dapat menyebabkan model mengalami *overfitting* atau *underfitting*, sehingga menurunkan akurasi prediksi secara signifikan (Ahmad et al., 2023). Oleh karena itu, proses optimasi menjadi tahap yang Berbagai strategi optimasi telah dikembangkan untuk mengatasi tantangan tersebut. Metode optimasi konvensional seperti *grid search* dan *random search* sering kali memerlukan waktu komputasi yang besar, terutama ketika ruang pencarian luas. Sebagai alternatif, metode optimasi berbasis metaheuristik dan probabilistik seperti *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization* banyak digunakan karena mampu mengeksplorasi ruang pencarian secara lebih efisien (Yang & Shami, 2020) (Zulfiqar et al., 2022). Metode-metode ini memiliki karakteristik pencarian yang berbeda, sehingga efektivitasnya dapat bervariasi tergantung pada karakteristik data dan model yang digunakan.

Dengan menerapkan optimasi yang tepat, XGBoost berpotensi menghasilkan model prediksi yang lebih akurat, robust, dan stabil. Dalam konteks kesehatan mental siswa sekolah menengah, model prediksi yang andal dapat berfungsi sebagai alat

bantu deteksi dini untuk mengidentifikasi siswa yang berisiko mengalami gangguan kesehatan mental. Penting untuk ditekankan bahwa penggunaan *machine learning* dalam penelitian ini tidak dimaksudkan sebagai alat diagnosis klinis, melainkan sebagai sistem pendukung keputusan yang membantu pihak sekolah dalam memahami pola risiko dan merancang intervensi preventif yang lebih tepat sasaran (Wang, 2025).

Pendekatan ini sejalan dengan tren penelitian terkini yang memanfaatkan *machine learning* tidak hanya untuk tujuan diagnosis, tetapi juga untuk prediksi preventif dan perencanaan intervensi berbasis data dalam bidang kesehatan mental (Lewin et al., 2025). Dengan demikian, landasan teori mengenai *machine learning* dalam penelitian ini menjadi dasar penting untuk memahami rasionalitas pemilihan algoritma XGBoost Regressor dan strategi optimasi yang digunakan, serta relevansinya dalam konteks prediksi kesehatan mental siswa sekolah menengah.

2.3.3. XGBoost Regressor

XGBoost Regressor merupakan salah satu algoritma *ensemble learning* berbasis *Gradient Boosting* yang dikembangkan untuk meningkatkan performa prediksi pada permasalahan klasifikasi maupun regresi (Chen & Guestrin, 2016). Algoritma ini dirancang untuk mengatasi keterbatasan metode *boosting* konvensional melalui optimasi komputasi, penerapan regularisasi yang lebih kuat, serta kemampuan menangani data berdimensi tinggi secara efisien. Keunggulan tersebut menjadikan XGBoost sebagai salah satu algoritma yang paling banyak digunakan

dalam berbagai kompetisi dan penelitian *machine learning*, termasuk pada domain kesehatan.

Dalam konteks prediksi kesehatan mental siswa sekolah menengah, XGBoost Regressor dipilih karena kemampuannya memodelkan hubungan nonlinier dan interaksi kompleks antar variabel. Faktor-faktor risiko kesehatan mental, seperti tekanan akademik, dukungan keluarga, kualitas hubungan sosial, dan kondisi emosional, tidak berdiri secara independen, melainkan saling memengaruhi satu sama lain. Hubungan semacam ini sulit ditangkap oleh metode regresi linier konvensional yang mengasumsikan hubungan linier dan independensi antar variabel. Oleh karena itu, penggunaan model berbasis pohon keputusan yang digabungkan melalui mekanisme *boosting* menjadi lebih sesuai untuk memodelkan kompleksitas data psikososial.

Secara konseptual, XGBoost membangun model prediksi secara aditif melalui penjumlahan sejumlah pohon keputusan (*Decision Trees*). Setiap pohon keputusan berfungsi sebagai *weak learner* yang secara bertahap memperbaiki kesalahan prediksi dari pohon sebelumnya. Pendekatan ini memungkinkan model untuk fokus pada pola-pola data yang sulit diprediksi pada iterasi awal, sehingga akurasi model meningkat secara progresif. Secara matematis, model prediksi XGBoost dapat dirumuskan sebagai berikut:

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in F$$

dengan:

\hat{y}_i = hasil prediksi untuk data ke - i

K = jumlah pohon keputusan

f_k = fungsi regresi berupa pohon keputusan

F = ruang fungsi semua pohon Keputusan

Formulasi tersebut menunjukkan bahwa prediksi akhir diperoleh dari agregasi kontribusi setiap pohon keputusan yang dibangun selama proses pelatihan. Setiap pohon memodelkan sebagian kecil dari struktur data, sehingga kombinasi seluruh pohon mampu menangkap pola yang lebih kompleks dibandingkan satu model tunggal. Untuk memperoleh model yang optimal, XGBoost meminimalkan suatu *objective function* yang merupakan kombinasi antara fungsi loss dan fungsi regularisasi. Fungsi objektif ini dirumuskan sebagai berikut:

$$Obj(\theta) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k)$$

dengan:

$l(y_i, \hat{y}_i)$ = fungsi loss (misalnya *Mean Squared Error* untuk regresi)

$\Omega(f_k)$ = fungsi regularisasi untuk mengontrol kompleksitas model

Komponen fungsi loss bertujuan untuk meminimalkan selisih antara nilai prediksi dan nilai aktual, sedangkan fungsi regularisasi berperan dalam mengendalikan kompleksitas model. Regularisasi ini penting untuk mencegah terbentuknya pohon keputusan yang terlalu dalam atau terlalu kompleks, yang dapat menyebabkan *overfitting* terhadap data latih. Dengan demikian, XGBoost tidak hanya berfokus pada pencapaian akurasi tinggi, tetapi juga pada kemampuan generalisasi model terhadap data baru.

Keunggulan lain dari XGBoost Regressor adalah kemampuannya dalam mengelola *bias-variance trade-off*. Dengan mengombinasikan banyak *weak learners* dan menerapkan regularisasi, XGBoost mampu menekan varians tanpa meningkatkan bias secara signifikan. Hal ini sangat relevan dalam konteks data kesehatan mental siswa, yang umumnya mengandung noise, subjektivitas, serta variasi individu yang tinggi. Model yang terlalu sederhana berisiko menghasilkan bias yang besar, sementara model yang terlalu kompleks berpotensi mengalami *overfitting*. XGBoost menawarkan keseimbangan yang lebih baik di antara kedua kondisi tersebut.

Selain itu, XGBoost mendukung berbagai mekanisme optimasi, seperti *shrinkage* melalui learning rate, *subsampling* data, dan pemilihan fitur secara acak. Mekanisme ini membantu meningkatkan stabilitas model dan efisiensi komputasi, terutama ketika jumlah fitur cukup banyak dan interaksi antar fitur bersifat kompleks. Dalam prediksi kesehatan mental, di mana variabel akademik, sosial, dan emosional saling berkaitan, mekanisme ini memungkinkan model untuk menangkap pola yang relevan tanpa terlalu sensitif terhadap fluktuasi data.

Meskipun memiliki berbagai keunggulan, performa XGBoost Regressor sangat bergantung pada pemilihan nilai yang digunakan. Parameter seperti learning rate, max depth, jumlah estimator, dan subsample secara langsung memengaruhi kompleksitas model dan kualitas prediksi. Oleh karena itu, untuk memaksimalkan potensi XGBoost dalam memprediksi kesehatan mental siswa sekolah menengah, diperlukan proses optimasi yang sistematis dan efisien. Hal inilah yang menjadi dasar penggunaan metode optimasi seperti *Genetic Algorithm*, *Particle Swarm*

Optimization, dan *Bayesian Optimization* dalam penelitian ini, yang akan dibahas pada subbab selanjutnya.

2.3.4. Hyperparameter Tuning

Dalam konteks *machine learning*, pemilihan *hyperparameter* yang tepat merupakan faktor kunci dalam menentukan kinerja dan stabilitas model prediktif. Berbeda dengan parameter model yang dipelajari secara otomatis selama proses pelatihan, *hyperparameter* ditentukan sebelum proses pembelajaran dimulai dan berfungsi untuk mengatur perilaku algoritma secara keseluruhan. Pada algoritma XGBoost Regressor, *hyperparameter* seperti *learning rate*, *max depth*, *n_estimators*, *subsample*, serta parameter regularisasi tidak dipelajari langsung dari data, tetapi harus ditetapkan secara eksplisit oleh peneliti. Pemilihan nilai *hyperparameter* ini memiliki pengaruh signifikan terhadap kecepatan konvergensi, kompleksitas model, serta kemampuan generalisasi terhadap data baru (Chen & Guestrin, 2016).

Secara konseptual, *learning rate* mengontrol seberapa besar kontribusi setiap pohon keputusan terhadap model akhir, *max depth* menentukan tingkat kompleksitas struktur pohon, sedangkan *n_estimators* mengatur jumlah pohon keputusan yang dibangun. Parameter *subsample* dan *colsample* berperan dalam mengatur proporsi data dan fitur yang digunakan pada setiap iterasi, sehingga membantu mengurangi varians model. Jika nilai *hyperparameter* terlalu kecil, model cenderung belajar secara lambat dan berisiko mengalami *underfitting*. Sebaliknya, nilai *hyperparameter* yang terlalu besar dapat menyebabkan model menjadi terlalu

kompleks dan rentan terhadap *overfitting*, khususnya pada data yang mengandung noise dan subjektivitas seperti data kesehatan mental.

Proses *hyperparameter tuning* bertujuan untuk mencari kombinasi *hyperparameter* optimal θ^* yang meminimalkan fungsi objektif XGBoost, yaitu kombinasi antara fungsi *loss* dan fungsi regularisasi. Secara matematis, proses ini dapat dirumuskan sebagai berikut::

$$\theta^* = \arg \min_{\theta} \left(\sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \right)$$

dengan:

$l(y_i, \hat{y}_i)$: fungsi *loss* yang mengukur kesalahan prediksi (misalnya *Mean Squared Error* untuk regresi) (misalnya *Mean Squared Error*)

$\Omega(f_k)$: fungsi regularisasi yang mengontrol kompleksitas model melalui struktur pohon keputusan.

Formulasi ini menunjukkan bahwa tujuan optimasi tidak hanya meminimalkan kesalahan prediksi, tetapi juga menjaga kompleksitas model agar tetap mampu melakukan **generalisasi dengan baik**. Dalam konteks prediksi kesehatan mental, keseimbangan antara akurasi dan generalisasi menjadi sangat penting karena data yang digunakan bersifat psikososial, subjektif, dan dipengaruhi oleh berbagai faktor laten yang tidak seluruhnya dapat diobservasi secara langsung.

Tantangan utama dalam *hyperparameter tuning* terletak pada besarnya ruang pencarian yang harus dijelajahi. Setiap *hyperparameter* memiliki rentang nilai yang

luas, dan kombinasi antar *hyperparameter* menghasilkan ruang pencarian yang bersifat eksponensial. Metode konvensional seperti *grid search* dan *random search* sering digunakan sebagai pendekatan awal, namun keduanya memiliki keterbatasan. *Grid search* membutuhkan waktu komputasi yang sangat besar karena mengevaluasi seluruh kombinasi yang mungkin, sedangkan *random search* meskipun lebih efisien, tetap tidak menjamin ditemukannya kombinasi *hyperparameter* yang optimal, terutama pada ruang pencarian yang kompleks.

Seiring meningkatnya kompleksitas model dan besarnya ruang pencarian *hyperparameter* pada XGBoost Regressor, diperlukan metode optimasi yang lebih efisien dan adaptif dibandingkan pendekatan konvensional. Oleh karena itu, berbagai algoritma optimasi modern berbasis *metaheuristik* dan probablistik mulai banyak digunakan dalam penelitian *machine learning*. Pendekatan ini dirancang untuk menyeimbangkan eksplorasi ruang pencarian dan eksploitasi solusi terbaik yang telah ditemukan, sehingga mampu menemukan kombinasi *hyperparameter* yang lebih optimal dengan biaya komputasi yang relatif lebih rendah.

Beberapa metode optimasi yang banyak digunakan antara lain *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization*. *Genetic Algorithm* meniru mekanisme evolusi biologis melalui proses seleksi, *crossover*, dan mutasi untuk menghasilkan solusi yang semakin baik dari generasi ke generasi. *Particle Swarm Optimization* terinspirasi dari perilaku sosial kawanan, di mana solusi kandidat bergerak dalam ruang pencarian berdasarkan pengalaman individu dan kelompok. Sementara itu, *Bayesian Optimization* menggunakan pendekatan

probabilistik untuk memodelkan fungsi objektif dan menentukan titik pencarian berikutnya secara adaptif dengan menyeimbangkan eksplorasi dan eksploitasi.

Ketiga metode optimasi tersebut menawarkan pendekatan yang berbeda dalam menemukan kombinasi *hyperparameter* optimal. Efektivitas masing-masing metode sangat bergantung pada karakteristik data, struktur model, serta tujuan optimasi yang ingin dicapai. Dalam konteks prediksi kesehatan mental siswa sekolah menengah, perbedaan karakteristik data psikososial berpotensi memengaruhi kinerja setiap metode optimasi. Oleh karena itu, penting untuk membahas dan membandingkan ketiga metode tersebut secara lebih rinci guna memahami kelebihan dan keterbatasan masing-masing dalam meningkatkan performa prediksi XGBoost Regressor. Pembahasan ini menjadi landasan bagi analisis komparatif yang dilakukan pada bab selanjutnya.

2.3.5. Genetic Algorithm

Genetic Algorithm pertama kali diperkenalkan oleh John Holland melalui karyanya *Adaptation in Natural and Artificial Systems* pada tahun 1975. Algoritma ini dikembangkan berdasarkan prinsip seleksi alam yang diperkenalkan oleh Charles Darwin, di mana individu dengan karakteristik terbaik memiliki peluang lebih besar untuk bertahan hidup dan bereproduksi. Prinsip evolusi biologis tersebut kemudian diadaptasi ke dalam konteks komputasi sebagai metode pencarian solusi optimal pada permasalahan optimasi yang memiliki ruang pencarian luas dan kompleks.

Dalam bidang komputasi, *Genetic Algorithm* termasuk ke dalam kategori algoritma metaheuristik yang dirancang untuk menyelesaikan permasalahan

optimasi, baik yang bersifat diskrit maupun kontinu. Solusi potensial direpresentasikan dalam bentuk kromosom, yang masing-masing terdiri atas gen-gen yang merepresentasikan parameter atau variabel keputusan. Kualitas setiap solusi dievaluasi menggunakan suatu fungsi evaluasi yang dikenal sebagai *fitness function*, yang menggambarkan seberapa baik solusi tersebut dalam menyelesaikan permasalahan yang dihadapi (Li et al., 2022). Melalui mekanisme evolusioner ini, *Genetic Algorithm* mampu melakukan pencarian solusi secara adaptif dan global dalam ruang pencarian yang luas.

Mekanisme kerja *Genetic Algorithm* melibatkan tiga operator utama, yaitu seleksi, *crossover*, dan mutasi. Operator seleksi berfungsi untuk memilih individu-individu terbaik dari populasi berdasarkan nilai *fitness* yang diperoleh, sehingga solusi dengan kualitas lebih baik memiliki peluang lebih besar untuk diwariskan ke generasi berikutnya (Bajpai, 2010). Proses *crossover* mengombinasikan dua kromosom terpilih untuk menghasilkan kromosom baru yang mewarisi karakteristik dari kedua induknya, sehingga memungkinkan eksplorasi kombinasi solusi yang lebih beragam (Suratno & Rarasati, 2019). Sementara itu, operator mutasi memperkenalkan variasi acak pada gen tertentu dalam kromosom, yang bertujuan menjaga keberagaman populasi dan mencegah algoritma terjebak pada solusi lokal.

Secara umum, siklus iteratif *Genetic Algorithm* terdiri atas beberapa tahapan utama, yaitu inisialisasi populasi awal, evaluasi nilai *fitness* setiap individu, proses seleksi, *crossover*, mutasi, pembentukan populasi baru, serta terminasi berdasarkan kriteria tertentu seperti tercapainya jumlah generasi maksimum atau konvergensi

nilai *fitness* (Ismail & Irhamah, 2008). Proses ini berlangsung secara berulang hingga diperoleh solusi yang dianggap optimal atau mendekati optimal.

Secara matematis, fungsi *fitness* dalam *Genetic Algorithm* dapat didefinisikan sesuai dengan permasalahan yang diselesaikan. Pada permasalahan regresi, fungsi *Mean Squared Error* (MSE) sering digunakan sebagai ukuran *fitness* karena mampu merepresentasikan besarnya kesalahan prediksi model. Fungsi *fitness* tersebut dapat dirumuskan sebagai berikut:

$$f(x) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i(x))^2$$

dengan

y_i : nilai aktual data ke- i ,

$\hat{y}_i(x)$: sebagai prediksi model menggunakan kromosom x


$f(x)$: nilai *fitness* yang diminimalkan.

Fungsi ini memastikan bahwa kromosom dengan kesalahan prediksi yang lebih kecil akan memiliki nilai *fitness* yang lebih baik dan peluang lebih besar untuk dipertahankan dalam populasi pada generasi berikutnya (Ali et al., 2023). Dengan demikian, proses evolusi dalam *Genetic Algorithm* secara bertahap mengarahkan populasi menuju solusi dengan performa prediksi yang lebih optimal.

Kelebihan utama *Genetic Algorithm* terletak pada kemampuannya menjelajahi ruang solusi yang luas secara global, fleksibilitasnya dalam menangani permasalahan diskrit maupun kontinu, serta tidak memerlukan informasi turunan atau gradien dari

fungsi objektif yang dioptimasi (Papazoglou & Biskas, 2023). Karakteristik ini menjadikan *Genetic Algorithm* sangat sesuai untuk optimasi *hyperparameter* pada model *machine learning* yang memiliki ruang pencarian kompleks dan tidak konveks, seperti XGBoost Regressor. Namun demikian, *Genetic Algorithm* juga memiliki beberapa keterbatasan, antara lain kebutuhan komputasi yang relatif tinggi akibat banyaknya evaluasi *fitness* serta risiko *premature convergence*, di mana populasi dapat berhenti berevolusi pada solusi lokal yang belum tentu optimal secara global.

Meskipun memiliki keterbatasan tersebut, keunggulan *Genetic Algorithm* menjadikannya salah satu algoritma optimasi yang banyak digunakan dalam berbagai bidang, seperti perencanaan, desain sistem, optimasi sumber daya, serta optimasi parameter pada model *machine learning*. Dalam konteks penelitian ini, *Genetic Algorithm* digunakan untuk mengoptimasi *hyperparameter* XGBoost Regressor dengan tujuan meningkatkan akurasi dan stabilitas model prediksi kesehatan mental siswa sekolah menengah. Menurut (Li et al., 2022), tahapan kerja *Genetic Algorithm* dapat divisualisasikan dalam bentuk *flowchart* seperti yang ditunjukkan pada Gambar 2.1.



Gambar 2. 1 Alur Algoritma *Genetic Algorithm*

Dalam konteks optimasi *hyperparameter*, proses dimulai dengan inisialisasi populasi awal, di mana setiap kromosom merepresentasikan sebuah kombinasi nilai *hyperparameter* XGBoost, seperti *learning rate*, *max depth*, *n_estimators*, dan *subsample*. Populasi awal ini dibangkitkan secara acak untuk memastikan ruang pencarian dapat dieksplorasi secara luas dan tidak bias terhadap kombinasi tertentu.

Selanjutnya, dilakukan proses evaluasi dan seleksi untuk memilih kromosom terbaik berdasarkan fungsi *fitness* yang telah ditentukan. Dalam penelitian ini, fungsi *fitness* umumnya menggunakan metrik kesalahan prediksi, seperti MSE atau RMSE, sehingga kromosom dengan nilai kesalahan yang lebih kecil dianggap memiliki kualitas yang lebih baik. Individu-individu terbaik kemudian dipertahankan dan digunakan untuk membentuk populasi generasi berikutnya.

Apabila kondisi penghentian belum tercapai, dilakukan proses *crossover* untuk menggabungkan pasangan kromosom terpilih sehingga menghasilkan

kombinasi *hyperparameter* baru yang berpotensi memiliki kinerja lebih baik. Setelah itu, proses mutasi diterapkan dengan memodifikasi sebagian kecil gen dalam kromosom secara acak untuk menjaga keberagaman populasi dan mencegah terjebaknya algoritma pada solusi lokal. Proses seleksi, *crossover*, dan mutasi ini berlangsung secara iteratif hingga kriteria terminasi terpenuhi.

Pada akhirnya, *Genetic Algorithm* menghasilkan kombinasi *hyperparameter* XGBoost Regressor yang optimal atau mendekati optimal. Kombinasi ini diharapkan mampu meningkatkan performa model dalam memprediksi kesehatan mental siswa sekolah menengah secara lebih akurat dan stabil, sehingga mendukung tujuan penelitian dalam mengkaji efektivitas optimasi *hyperparameter* berbasis metaheuristik.

2.3.6. Particle Swarm Optimization

Particle Swarm Optimization pertama kali diperkenalkan oleh Kennedy dan Eberhart pada tahun 1995, dengan inspirasi dari perilaku sosial kawanan burung dan ikan dalam mencari makanan. Algoritma ini termasuk dalam kategori *population-based optimization*, di mana sekumpulan partikel digunakan sebagai representasi solusi potensial yang bergerak secara kolektif dalam ruang pencarian. Setiap partikel merepresentasikan satu solusi kandidat, yang dicirikan oleh dua komponen utama, yaitu posisi yang menunjukkan nilai solusi dan kecepatan yang menentukan arah serta besar pergerakan partikel pada iterasi berikutnya (Kennedy & Eberhart, 1995).

Konsep dasar *Particle Swarm Optimization* menekankan pada kolaborasi dan berbagi informasi antar partikel dalam populasi. Setiap partikel tidak hanya

mengandalkan pengalaman individualnya sendiri, tetapi juga memanfaatkan informasi terbaik yang diperoleh oleh seluruh populasi. Dalam mekanisme ini, setiap partikel dipengaruhi oleh dua komponen utama, yaitu *personal best* (*pbest*), yang merupakan posisi terbaik yang pernah dicapai oleh partikel tersebut, dan *global best* (*gbest*), yang merupakan posisi terbaik yang pernah dicapai oleh seluruh partikel dalam populasi. Pendekatan ini memungkinkan swarm untuk bergerak menuju area ruang pencarian yang memiliki kualitas solusi lebih baik secara kolektif.

Secara matematis, proses pembaruan kecepatan dan posisi partikel dalam PSO dapat dirumuskan sebagai berikut (Shi & Eberhart, 1998):

$$v_i^{t+1} = w \cdot v_i^t + c_1 \cdot r_1 \cdot (pbest_i - x_i^t) + c_2 \cdot r_2 \cdot (gbest - x_i^t)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1}$$

dengan:

v_i^t : kecepatan partikel ke-i pada iterasi ke-t

x_i^t : posisi partikel ke-i pada iterasi ke-t

$pbest_i$: posisi terbaik yang pernah dicapai partikel ke-i

$gbest$: posisi terbaik yang pernah dicapai seluruh populasi

w : bobot inersia yang mengontrol kontribusi kecepatan sebelumnya

c_1, c_2 : koefisien akselerasi (*cognitive* dan *social*)

r_1, r_2 : bilangan acak uniform antara 0 dan 1

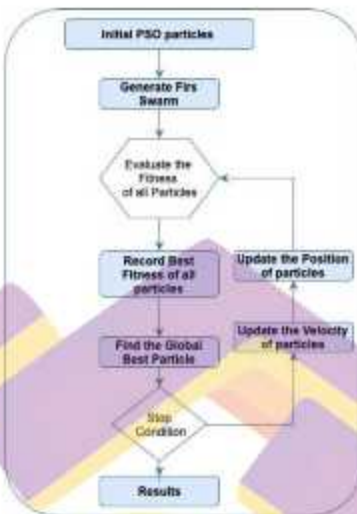
Melalui persamaan tersebut, setiap partikel memperbarui kecepatannya berdasarkan kombinasi dari pengalaman individu dan pengalaman kolektif. Bobot inersia (w) berperan penting dalam menyeimbangkan proses eksplorasi dan eksploitasi. Nilai bobot inersia yang besar mendorong eksplorasi ruang pencarian

yang lebih luas, sedangkan nilai yang kecil mendorong eksploitasi di sekitar solusi terbaik yang telah ditemukan. Keseimbangan antara kedua proses ini sangat penting untuk menghindari konvergensi prematur pada solusi lokal.

Salah satu keunggulan utama PSO dibandingkan metode optimasi lainnya adalah kesederhanaan konsep dan implementasinya. PSO memiliki jumlah parameter yang relatif sedikit dan mudah disesuaikan, serta mampu mencapai konvergensi dengan cepat. Karakteristik ini menjadikan PSO sangat menarik untuk diterapkan pada permasalahan optimasi *hyperparameter* dalam *machine learning*, termasuk pada model XGBoost Regressor. Selain itu, PSO tidak memerlukan informasi gradien dari fungsi objektif, sehingga cocok digunakan pada permasalahan dengan fungsi objektif yang kompleks dan tidak terdiferensiasi.

Namun demikian, PSO juga memiliki beberapa keterbatasan. Salah satu kelemahan utama PSO adalah kecenderungannya untuk cepat konvergen ke solusi lokal apabila parameter seperti bobot inersia dan koefisien akselerasi tidak diatur dengan tepat (Poli et al., 2007). Selain itu, pada beberapa kasus, keberagaman partikel dapat menurun secara cepat, sehingga eksplorasi ruang pencarian menjadi terbatas. Oleh karena itu, pemilihan parameter PSO yang tepat menjadi faktor penting dalam memastikan keberhasilan proses optimasi.

Menurut Shi & Eberhart (1998), tahapan kerja PSO dapat divisualisasikan dalam bentuk *flowchart* seperti yang ditunjukkan pada Gambar 2.9.



Gambar 2. 2 Alur *Particle Swarm Optimization*

Dalam konteks optimasi *hyperparameter*, proses PSO dimulai dengan inisialisasi swarm, di mana setiap partikel merepresentasikan sebuah kombinasi nilai *hyperparameter* XGBoost, seperti *learning rate*, *max depth*, *n_estimators*, dan *subsample*. Posisi awal dan kecepatan awal partikel biasanya diinisialisasi secara acak untuk memastikan ruang pencarian dieksplorasi secara luas.

Setiap partikel kemudian dievaluasi menggunakan fungsi *fitness* yang telah ditentukan, umumnya berupa nilai kesalahan prediksi seperti *Root Mean Squared Error* (RMSE) atau *Mean Absolute Error* (MAE) dari hasil prediksi model XGBoost Regressor. Nilai *fitness* ini digunakan untuk memperbarui *pbest* masing-masing partikel serta menentukan *gbest* pada tingkat populasi. Selanjutnya, posisi dan kecepatan setiap partikel diperbarui berdasarkan nilai *pbest* dan *gbest* yang diperoleh.

Proses evaluasi dan pembaruan partikel ini berlangsung secara iteratif hingga kondisi penghentian terpenuhi, misalnya ketika jumlah iterasi maksimum tercapai atau tidak terdapat peningkatan signifikan pada nilai *fitness*. Pada akhir proses, PSO menghasilkan kombinasi *hyperparameter* yang dianggap optimal atau mendekati optimal. Kombinasi ini diharapkan mampu meningkatkan performa prediksi XGBoost Regressor dalam memodelkan kesehatan mental siswa sekolah menengah secara lebih akurat dan stabil.

2.3.7. Bayesian Optimization

Bayesian Optimization merupakan metode optimasi berbasis probabilistik yang dirancang untuk mencari solusi optimal pada fungsi objektif yang mahal secara komputasi (*computationally expensive*). Metode ini sangat relevan dalam konteks *hyperparameter tuning* pada model *machine learning*, di mana setiap evaluasi fungsi objektif membutuhkan proses pelatihan dan pengujian model yang relatif memakan waktu. Berbeda dengan pendekatan optimasi konvensional yang bersifat eksploratif secara menyeluruh, *Bayesian Optimization* memanfaatkan informasi dari evaluasi sebelumnya untuk mengarahkan pencarian solusi secara lebih efisien dan terstruktur.

Prinsip utama *Bayesian Optimization* adalah membangun suatu *surrogate model* yang berfungsi sebagai aproksimasi dari fungsi objektif sebenarnya. *Surrogate model* ini digunakan untuk memodelkan hubungan antara kombinasi *hyperparameter* dan performa model prediksi. Salah satu model *surrogate* yang paling umum digunakan adalah Gaussian Process (GP), karena kemampuannya dalam memodelkan ketidakpastian dan memberikan estimasi probabilistik terhadap nilai

fungsi objektif. Gaussian Process memodelkan fungsi target sebagai distribusi probabilitas normal sebagai berikut:

$$f(x) \sim \mathcal{N}(\mu(x), \delta^2(x))$$

dengan

$f(x)$: dimodelkan sebagai variabel acak yang mengikuti distribusi normal (Gaussian).

$\mu(x)$: **mean function** yang merepresentasikan perkiraan nilai rata-rata performa model (prediksi pusat).

$\delta^2(x)$: **variance function** yang merepresentasikan tingkat **ketidakpastian** dari prediksi tersebut.

Pendekatan ini memungkinkan *Bayesian Optimization* tidak hanya memperkirakan nilai performa model pada kombinasi *hyperparameter* tertentu, tetapi juga mengukur tingkat ketidakpastian dari perkiraan tersebut. Informasi ketidakpastian ini menjadi komponen penting dalam menentukan strategi pencarian solusi berikutnya.

Untuk memilih kombinasi *hyperparameter* berikutnya yang akan dievaluasi, *Bayesian Optimization* menggunakan fungsi akuisisi (*acquisition function*). Fungsi ini berperan sebagai mekanisme pengambilan keputusan yang menyeimbangkan antara eksploitasi dan eksplorasi. Salah satu fungsi akuisisi yang paling banyak digunakan adalah *Expected Improvement* (EI), yang dirumuskan sebagai berikut:

$$EI(x) = (\mu(x) - f(x^+) - \xi) \Phi(Z) + \sigma(x) \phi(Z)$$

dengan

$\mu(x)$: prediksi **mean** dari Gaussian Process di titik (x)

$\sigma(x)$: prediksi **standar deviasi** (akar dari varians) di titik (x)

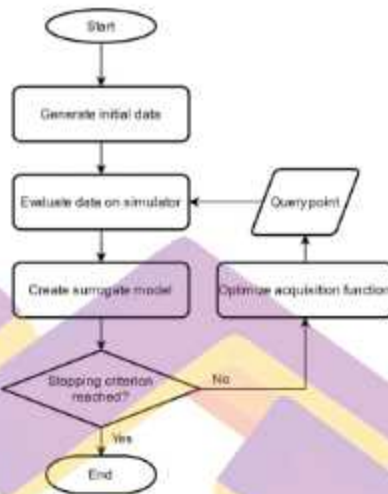
$f(x^+)$: nilai terbaik (misalnya akurasi tertinggi atau error terendah) yang sudah ditemukan sejauh ini.

ξ : parameter kecil (biasanya positif) untuk mengatur keseimbangan antara **eksplorasi** dan **eksploitasi**.

$\Phi(Z)$: **fungsi distribusi kumulatif (CDF)** dari distribusi normal standar.

$\phi(Z)$: **fungsi densitas probabilitas (PDF)** dari distribusi normal standar.

Intuisi dari fungsi *Expected Improvement* adalah memilih titik *hyperparameter* yang memiliki potensi perbaikan terbesar dibandingkan solusi terbaik yang telah ditemukan. Titik dengan nilai $\mu(x)$ tinggi mendorong eksploitasi solusi yang menjanjikan, sementara titik dengan nilai $\sigma(x)$ tinggi mendorong eksplorasi area ruang pencarian yang masih memiliki ketidakpastian besar. Dengan demikian, *Bayesian Optimization* mampu menyeimbangkan kedua strategi tersebut secara adaptif. Tahapan kerja *Bayesian Optimization* secara umum dapat divisualisasikan seperti pada Gambar 2.4.



Gambar 2. 3 Alur *Bayesian Optimization*

Proses *Bayesian Optimization* dimulai dengan pembangkitan data awal (*initial design*), yaitu sejumlah kombinasi *hyperparameter* yang dipilih secara acak atau menggunakan rancangan eksperimental tertentu. Kombinasi awal ini mencakup *hyperparameter* penting pada XGBoost Regressor, seperti *learning rate*, *max depth*, *subsample*, dan *colsample bytree*. Setiap kombinasi kemudian dievaluasi dengan melatih model XGBoost Regressor dan mengukur performanya menggunakan metrik evaluasi, misalnya *Root Mean Squared Error (RMSE)*.

Berdasarkan hasil evaluasi awal tersebut, *Bayesian Optimization* membangun *surrogate model* menggunakan Gaussian Process yang memodelkan hubungan antara *hyperparameter* dan performa model. Tahapan selanjutnya adalah optimasi fungsi akuisisi, yang bertujuan menentukan kandidat *hyperparameter* baru yang paling menjanjikan untuk dievaluasi pada iterasi berikutnya. Selain *Expected Improvement*,

fungsi akuisisi lain seperti *Probability of Improvement (PI)* dan *Upper Confidence Bound (UCB)* juga dapat digunakan, tergantung pada strategi pencarian yang diinginkan.

Kombinasi *hyperparameter* baru yang diusulkan oleh fungsi akuisisi kemudian dievaluasi kembali melalui proses pelatihan model, dan hasilnya digunakan untuk memperbarui *surrogate model*. Siklus ini berlangsung secara iteratif hingga kriteria penghentian tercapai, misalnya ketika jumlah iterasi maksimum terpenuhi, anggaran waktu komputasi habis, atau tidak terdapat peningkatan performa model yang signifikan.

Keunggulan utama *Bayesian Optimization* terletak pada efisiensi komputasinya. Dengan jumlah evaluasi fungsi objektif yang relatif lebih sedikit, BO mampu menemukan kombinasi *hyperparameter* yang optimal atau mendekati optimal dibandingkan metode pencarian brute force seperti *grid search*. Hal ini menjadikan *Bayesian Optimization* sangat sesuai untuk optimasi *hyperparameter* pada model XGBoost Regressor, terutama ketika proses pelatihan model memerlukan waktu komputasi yang cukup besar.

Dalam konteks prediksi kesehatan mental siswa sekolah menengah, penggunaan *Bayesian Optimization* diharapkan mampu menghasilkan konfigurasi *hyperparameter* yang tidak hanya meningkatkan akurasi prediksi, tetapi juga menjaga stabilitas dan kemampuan generalisasi model. Pendekatan probabilistik yang digunakan BO sangat relevan untuk data psikososial yang bersifat kompleks, heterogen, dan mengandung ketidakpastian tinggi. Oleh karena itu, *Bayesian Optimization* menjadi salah satu metode penting yang dibandingkan dalam penelitian

ini untuk mengevaluasi efektivitas optimasi *hyperparameter* pada XGBoost Regressor.

2.3.8. Evaluasi Model

Evaluasi model merupakan tahapan krusial dalam proses pembangunan model *machine learning*, karena berfungsi untuk menilai sejauh mana model mampu menghasilkan prediksi yang akurat, stabil, dan dapat digeneralisasikan pada data baru. Evaluasi yang tidak tepat berisiko menghasilkan model yang tampak baik pada data latih tetapi gagal memberikan prediksi yang andal pada data uji, suatu kondisi yang dikenal sebagai *overfitting*. Dalam konteks penelitian ini, evaluasi model menjadi sangat penting karena model yang dikembangkan digunakan untuk memprediksi kondisi kesehatan mental siswa sekolah menengah, yang datanya bersifat kompleks, subjektif, dan dipengaruhi oleh berbagai faktor psikososial.

Model yang digunakan dalam penelitian ini adalah XGBoost Regressor, sehingga metrik evaluasi yang dipilih difokuskan pada ukuran kinerja model regresi. Pemilihan metrik evaluasi tidak hanya didasarkan pada kemudahan perhitungan, tetapi juga pada relevansinya dalam menggambarkan kesalahan prediksi secara kuantitatif serta implikasi praktis dari kesalahan tersebut dalam konteks pendidikan dan kesehatan mental. Oleh karena itu, penelitian ini menggunakan kombinasi beberapa metrik evaluasi untuk memperoleh gambaran kinerja model yang lebih komprehensif.

Beberapa metrik evaluasi yang umum digunakan untuk mengukur kinerja model regresi adalah sebagai berikut. Pertama, *Mean Absolute Error (MAE)* yang

mengukur rata-rata nilai absolut selisih antara nilai aktual dan nilai prediksi. Metrik ini bersifat intuitif karena menunjukkan besarnya kesalahan prediksi secara langsung tanpa memperhatikan arah kesalahan. MAE dirumuskan sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Dengan

y_i : nilai actual

\hat{y}_i : nilai prediksi

n : jumlah data.

Kedua, *Mean Squared Error (MSE)*, yang menghitung rata-rata kuadrat selisih antara nilai aktual dan nilai prediksi. Dengan mengkuadratkan kesalahan, MSE memberikan penalti yang lebih besar terhadap kesalahan prediksi yang ekstrem. Rumus MSE dinyatakan sebagai berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Karakteristik ini menjadikan MSE sangat sensitif terhadap *outlier*. Dalam penelitian kesehatan mental, sensitivitas terhadap kesalahan besar menjadi penting karena kesalahan prediksi yang ekstrem dapat berimplikasi pada salah identifikasi siswa dengan risiko kesehatan mental yang tinggi. Oleh karena itu, MSE digunakan untuk mengevaluasi sejauh mana model mampu menghindari kesalahan prediksi yang besar.

Ketiga, **Root Mean Squared Error (RMSE)** yang merupakan akar kuadrat dari MSE dan memiliki satuan yang sama dengan variabel target. Hal ini menjadikan RMSE lebih mudah diinterpretasikan secara praktis dibandingkan MSE. Formula RMSE dituliskan sebagai berikut::

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

RMSE memberikan gambaran tentang besarnya kesalahan prediksi rata-rata dalam satuan asli data, sehingga sangat relevan dalam konteks prediksi kesehatan mental siswa. Nilai RMSE yang lebih kecil menunjukkan bahwa prediksi model cenderung lebih dekat dengan nilai aktual, sehingga model dianggap memiliki performa yang lebih baik.

Keempat, **Mean Absolute Percentage Error (MAPE)** mengukur kesalahan prediksi dalam bentuk persentase relatif terhadap nilai aktual. Metrik ini dirumuskan sebagai berikut:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

Keunggulan utama MAPE adalah sifatnya yang tidak bergantung pada skala data, sehingga memudahkan perbandingan kinerja model pada dataset dengan satuan atau rentang nilai yang berbeda. Namun demikian, MAPE memiliki keterbatasan, terutama ketika nilai aktual mendekati nol, yang dapat menyebabkan nilai MAPE menjadi sangat besar atau tidak terdefinisi. Selain itu, MAPE cenderung memberikan

bobot yang lebih besar pada kesalahan prediksi negatif. Oleh karena itu, dalam penelitian ini MAPE digunakan secara komplementer dengan metrik lain, bukan sebagai satu-satunya indikator kinerja model.

Selain metrik berbasis kesalahan, **Koefisien Determinasi (R^2)** digunakan untuk mengukur proporsi variasi variabel dependen yang dapat dijelaskan oleh model. Nilai R^2 berada pada rentang 0 hingga 1, di mana nilai yang semakin mendekati 1 menunjukkan bahwa model memiliki kemampuan yang lebih baik dalam menjelaskan variasi data. Koefisien determinasi dirumuskan sebagai berikut:

$$R = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

dengan \bar{y} sebagai rata-rata nilai aktual.

Dalam konteks penelitian ini, nilai R^2 digunakan untuk mengevaluasi sejauh mana model XGBoost Regressor mampu menjelaskan variasi kondisi kesehatan mental siswa berdasarkan indikator-indikator yang digunakan. Penting untuk dicatat bahwa pada data psikososial seperti kesehatan mental, nilai R^2 yang moderat tidak serta-merta menunjukkan kelemahan model, melainkan mencerminkan kompleksitas dan subjektivitas data yang sulit dimodelkan secara deterministik.

Untuk memastikan bahwa performa model yang diperoleh tidak terjadi secara kebetulan, evaluasi kinerja model juga dipandang dari sudut pandang statistik. Nilai R^2 yang diperoleh dievaluasi sebagai bagian dari *goodness-of-fit* model regresi, yang secara implisit merefleksikan signifikansi hubungan antara variabel prediktor dan variabel target. Dengan demikian, evaluasi model dalam penelitian ini tidak hanya

bersifat deskriptif, tetapi juga didukung oleh justifikasi statistik bahwa model memiliki kemampuan prediktif yang bermakna.

Secara keseluruhan, penggunaan kombinasi metrik MAE, MSE, RMSE, MAPE, dan R^2 memungkinkan evaluasi kinerja model dilakukan secara menyeluruh, baik dari sisi kesalahan absolut, sensitivitas terhadap *outlier*, interpretasi praktis, maupun kemampuan model dalam menjelaskan variasi data. Pendekatan evaluasi yang komprehensif ini diharapkan dapat memberikan gambaran yang lebih objektif dan seimbang mengenai kinerja XGBoost Regressor dalam memprediksi kesehatan mental siswa sekolah menengah.



BAB III

METODE PENELITIAN

3.1. Jenis, Sifat dan Pendekatan Penelitian

Penelitian ini merupakan penelitian kuantitatif dengan desain **komparatif-eksperimental**, yang bertujuan untuk membangun dan mengevaluasi model prediksi berbasis data numerik, serta membandingkan kinerja beberapa metode optimasi terhadap satu model utama. Pendekatan kuantitatif dipilih karena penelitian ini berfokus pada pengolahan data numerik, pengukuran kinerja model secara matematis, serta analisis hasil prediksi menggunakan metrik statistik.

Sifat penelitian ini bersifat **deskriptif dan eksplanatif**. Bersifat deskriptif karena penelitian ini menjelaskan secara sistematis tahapan pengolahan data, pembangunan model, serta proses optimasi yang dilakukan. Bersifat eksplanatif karena penelitian ini berupaya menjelaskan pengaruh optimasi terhadap peningkatan kinerja model prediksi, serta mengkaji perbedaan performa yang dihasilkan oleh masing-masing metode optimasi.

Pendekatan yang digunakan adalah pendekatan eksperimental berbasis *machine learning*, di mana model dibangun, dilatih, dan dievaluasi secara berulang menggunakan konfigurasi yang berbeda. Algoritma utama yang digunakan adalah XGBoost Regressor, yang dipilih karena kemampuannya dalam memodelkan hubungan nonlinier dan menangani data berdimensi tinggi. Untuk meningkatkan performa model, dilakukan optimasi menggunakan tiga metode yang berbeda, yaitu *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization*.

Perbandingan kinerja model hasil optimasi dilakukan untuk mengidentifikasi metode optimasi yang paling efektif dalam meningkatkan akurasi dan stabilitas prediksi. Dengan demikian, penelitian ini tidak hanya berfokus pada pencapaian performa terbaik, tetapi juga pada pemahaman karakteristik masing-masing metode optimasi dalam konteks prediksi kesehatan mental siswa sekolah menengah.

3.2. Metode Pengumpulan Data

Metode pengumpulan data dalam penelitian ini menggunakan **data sekunder** yang diperoleh dari sumber terbuka (*open data*). Pemanfaatan data sekunder dipilih karena keterbatasan akses terhadap data primer kesehatan mental siswa, serta untuk memastikan keterulangan (*reproducibility*) penelitian oleh peneliti lain.

Dataset yang digunakan berasal dari platform **Kaggle**, sebuah repositori daring yang menyediakan dataset publik untuk keperluan penelitian dan pengembangan *machine learning*. Dataset yang digunakan berjudul *High School Emotional Well-Being*, dan dapat diakses melalui tautan: <https://www.kaggle.com/datasets/jeffreyxshen/high-school-emotional-well-being/data>

Dataset tersebut berbentuk file CSV dan berisi data kesejahteraan emosional siswa sekolah menengah, yang mencakup berbagai variabel yang berpotensi memengaruhi kondisi kesehatan mental siswa. Variabel-variabel tersebut mencerminkan aspek psikososial, kebiasaan sehari-hari, serta kondisi emosional siswa dalam konteks lingkungan sekolah. Dataset ini dipilih karena memiliki

relevansi langsung dengan tujuan penelitian, kelengkapan atribut, serta format data yang sesuai untuk analisis regresi berbasis *machine learning*.

Penggunaan dataset publik juga memberikan keuntungan metodologis, yaitu memungkinkan hasil penelitian ini untuk dibandingkan secara langsung dengan penelitian terdahulu yang menggunakan dataset serupa, serta memudahkan proses validasi dan pengembangan penelitian lanjutan.

3.3. Metode Analisis Data

Metode analisis data dalam penelitian ini dilakukan melalui beberapa tahapan utama yang disusun secara sistematis untuk memastikan kualitas data dan validitas hasil prediksi. Analisis dimulai dengan pemahaman struktur dataset, yang terdiri atas atribut numerik dan kategorikal. Atribut-atribut tersebut dipilih karena relevansinya dalam menjelaskan kondisi kesejahteraan emosional siswa dari aspek sosial, psikologis, dan kebiasaan sehari-hari.

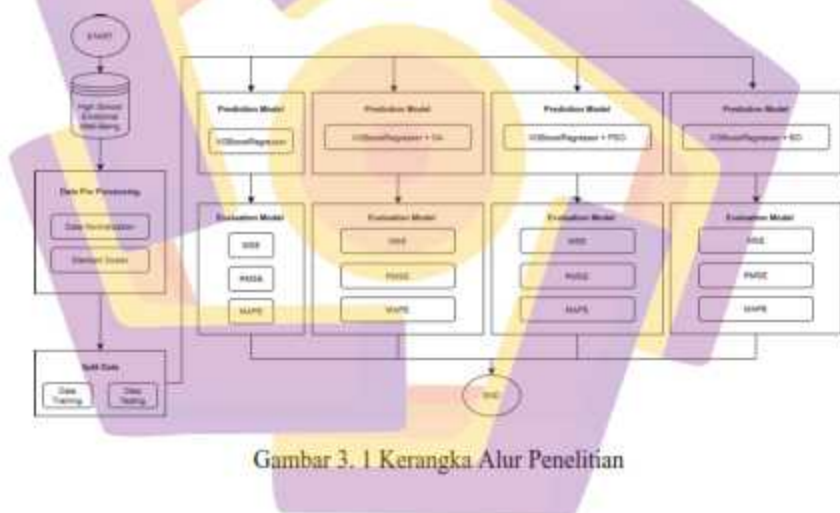
Tahap awal analisis melibatkan proses data preprocessing, yang bertujuan untuk mempersiapkan data agar sesuai dengan kebutuhan model *machine learning*. Proses ini mencakup penanganan atribut kategorikal, normalisasi data numerik, serta pembersihan data dari atribut yang tidak memberikan informasi yang signifikan. Seluruh tahapan preprocessing dilakukan untuk meminimalkan bias dan memastikan bahwa model dapat belajar dari data secara optimal.

Setelah preprocessing, data dianalisis menggunakan pendekatan regresi, karena variabel target dalam penelitian ini bersifat kontinu dan merepresentasikan tingkat kesejahteraan emosional siswa. Analisis regresi memungkinkan model

menghasilkan nilai prediksi yang lebih fleksibel dibandingkan pendekatan klasifikasi, yang cenderung menyederhanakan kondisi kesehatan mental ke dalam kategori diskret.

3.4. Alur Penelitian

Alur penelitian dalam mengidentifikasi dan memprediksi kesehatan mental siswa sekolah menengah dilakukan melalui beberapa tahapan yang saling berkaitan dan dilaksanakan secara berurutan. Tahapan-tahapan penelitian ini digambarkan dalam Gambar 3.1.



Gambar 3. 1 Kerangka Alur Penelitian

Penelitian diawali dengan studi literatur, yang bertujuan untuk mengidentifikasi permasalahan penelitian, memilih algoritma yang sesuai, serta menentukan metode optimasi yang relevan. Tahap ini menjadi dasar konseptual dalam merancang eksperimen dan menentukan metrik evaluasi yang digunakan.

Tahap selanjutnya adalah pengumpulan data, di mana data yang digunakan merupakan data sekunder yang diperoleh dari dataset publik Kaggle. Dataset ini terdiri atas data numerik dan kategorikal, yang kemudian diproses melalui tahap preprocessing data. Pada tahap ini, atribut kategorikal seperti *Sex* dikonversi ke dalam bentuk numerik menggunakan teknik *encoding*. Sementara itu, atribut *Parental Consent* dihapus dari dataset karena seluruh nilainya bersifat konstan ("Yes"), sehingga tidak memberikan variasi yang relevan untuk analisis prediksi.

Data numerik seperti *Sleep*, *Homework*, dan *Happiness* kemudian dinormalisasi atau distandarisasi menggunakan teknik *Min-Max Scaling* atau *Standard Scaler*. Proses ini bertujuan untuk memastikan bahwa seluruh fitur berada pada skala yang sebanding, sehingga tidak terjadi dominasi fitur tertentu dalam proses pelatihan model. Setelah preprocessing, dataset dibagi menjadi data training (80%) dan data testing (20%) untuk mengevaluasi kemampuan generalisasi model.

Tahap pemodelan dilakukan dalam dua skema utama, yaitu pembangunan model baseline dan model dengan optimasi. Model baseline dibangun menggunakan XGBoost Regressor tanpa optimasi, sedangkan model optimasi dibangun dengan menerapkan tiga metode optimasi, yaitu *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization*, yang dioptimalkan meliputi *learning rate*, *n_estimators*, *max_depth*, *subsample*, dan *colsample_bytree*.

Pada metode GA, proses optimasi dilakukan melalui mekanisme seleksi, *crossover*, dan mutasi untuk menghasilkan kombinasi terbaik. Metode PSO bekerja dengan memperbarui posisi partikel berdasarkan pengalaman terbaik individu dan

populasi. Sementara itu, BO memanfaatkan *surrogate model* dan fungsi akuisisi untuk mengarahkan pencarian secara efisien ke area yang paling menjanjikan.

Setelah seluruh model dilatih menggunakan data training, tahap evaluasi model dilakukan menggunakan data testing. Evaluasi ini bertujuan untuk mengukur kinerja model serta membandingkan efektivitas masing-masing metode optimasi. Metrik evaluasi yang digunakan meliputi *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Percentage Error* (MAPE) dan *Koefisien Determinasi* (R^2).

Penggunaan MSE bertujuan untuk mengidentifikasi kesalahan prediksi yang ekstrem, RMSE digunakan untuk interpretasi kesalahan dalam satuan asli data, MAPE memberikan gambaran kesalahan dalam bentuk persentase relatif, serta R^2 menjelaskan variasi kondisi kesehatan mental siswa berdasarkan variabel psikososial. Dengan pendekatan evaluasi ini, penelitian dapat menilai secara objektif sejauh mana optimasi mampu meningkatkan kinerja *XGBoost Regressor* dibandingkan model baseline.

BAB IV

HASIL PENELITIAN DAN PEMBAHASAN

Bab ini menyajikan hasil penelitian yang diperoleh berdasarkan seluruh tahapan eksperimen yang telah dilakukan, mulai dari pengolahan data, pembangunan model prediksi, hingga optimasi dan evaluasi kinerja model. Penyajian hasil pada bab ini disusun secara sistematis untuk memberikan gambaran yang jelas mengenai performa model *XGBoost Regressor* sebelum dan sesudah dilakukan optimasi, serta untuk menjawab rumusan masalah dan tujuan penelitian yang telah ditetapkan.

Pembahasan diawali dengan deskripsi singkat mengenai hasil preprocessing data, yang meliputi pengolahan atribut kategorikal, normalisasi data numerik, serta pembagian data menjadi data latih dan data uji. Tahapan ini bertujuan memastikan bahwa data yang digunakan telah memenuhi prasyarat untuk pemodelan regresi berbasis *machine learning*, sehingga hasil prediksi yang dihasilkan dapat dipertanggungjawabkan secara metodologis.

Selanjutnya, bab ini membahas hasil pembangunan model baseline menggunakan *XGBoost Regressor* tanpa optimasi. Model baseline digunakan sebagai acuan awal untuk menilai kinerja model prediksi sebelum dilakukan optimasi. Hasil dari model baseline kemudian dibandingkan dengan hasil model *XGBoost Regressor* yang telah dioptimasi menggunakan tiga metode optimasi, yaitu *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization*.

Evaluasi kinerja setiap model dilakukan menggunakan metrik *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute*

Percentage Error (MAPE), serta *Koefisien Determinasi* (R^2). Penggunaan beberapa metrik evaluasi bertujuan untuk memberikan gambaran yang lebih komprehensif mengenai performa model, baik dari sisi besarnya kesalahan prediksi, sensitivitas terhadap kesalahan ekstrem, maupun kemampuan model dalam menjelaskan variasi data kesehatan mental siswa.

Analisis komparatif dilakukan untuk mengidentifikasi perbedaan kinerja antara model baseline dan model hasil optimasi, serta untuk menentukan metode optimasi yang paling efektif dalam meningkatkan performa *XGBoost Regressor*. Pembahasan hasil tidak hanya difokuskan pada pencapaian nilai error terendah, tetapi juga pada stabilitas model dan relevansinya terhadap karakteristik data kesehatan mental yang bersifat psikososial dan subjektif.

Pada bagian akhir bab ini, hasil penelitian dikaitkan dengan temuan penelitian terdahulu untuk menunjukkan kesesuaian maupun perbedaan hasil yang diperoleh. Selain itu, dibahas pula keterbatasan penelitian yang berkaitan dengan karakteristik dataset dan pendekatan pemodelan yang digunakan. Dengan demikian, Bab IV diharapkan mampu memberikan pemahaman yang menyeluruh mengenai hasil penelitian serta implikasinya dalam konteks prediksi kesehatan mental siswa sekolah menengah.

4.1. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini berisi 468 entri data dengan 22 atribut yang merepresentasikan berbagai faktor psikososial yang berkaitan dengan kesejahteraan emosional dan kesehatan mental siswa sekolah menengah. Dataset ini

diperoleh dari survei daring yang dirancang untuk menangkap persepsi subjektif siswa terhadap kondisi emosional, sosial, dan lingkungan keluarga mereka. Karakteristik ini menjadikan dataset relevan untuk penelitian prediksi kesehatan mental, tetapi sekaligus menuntut pendekatan pemodelan yang mampu menangani kompleksitas dan subjektivitas data.

Atribut-atribut dalam dataset mencakup dimensi kebahagiaan subjektif, keterlibatan sosial, aktivitas ekstrakurikuler, kondisi keluarga, hubungan pertemanan, serta persepsi terhadap kesehatan mental secara umum. Contoh raw data dari dataset ditampilkan pada Tabel 4.1, yang menunjukkan variasi nilai antar responden pada atribut-atribut utama seperti durasi tidur, waktu belajar, tingkat kebahagiaan, dan kondisi kesehatan yang dilaporkan sendiri (self-reported health condition).

Tabel 4. 1 Deskripsi atribut dataset dan Raw data

Sex	Grade	Classes	Sleep	Homework	Freetime	Work	Extracurricular	Enjoyment Extracurri	Extraversio	Family	Stressness	Friends	Relationship	Loneliness	Happiness	SHC
0	10	6.0	7.0	4.0	1.0	0.0	15.0	5	3	4	5	3	1	3	4	4.00
1	12	4.0	6.0	3.0	6.0	0.0	11.0	5	3	4	5	5	6	3	5	4.75
0	11	4.0	6.0	4.0	2.0	30.0	12.0	4	6	4	3	6	1	4	4	3.25
0	9	0.0	5.0	1.0	7.0	0.0	0.0	1	1	2	3	3	1	1	1	1.25
0	9	1.0	8.0	3.0	5.0	0.0	12.0	6	1	2	3	3	1	1	2	2.50

Keberagaman nilai pada data mentah tersebut menunjukkan bahwa kondisi kesejahteraan emosional siswa tidak bersifat homogen. Perbedaan tingkat tidur, beban pekerjaan rumah, keterlibatan ekstrakurikuler, dan relasi sosial berpotensi menghasilkan pola yang kompleks dan nonlinier. Oleh karena itu, dataset ini dinilai

sesuai untuk dianalisis menggunakan pendekatan *machine learning* berbasis regresi, khususnya algoritma *ensemble* seperti XGBoost Regressor yang mampu memodelkan interaksi antar variabel secara lebih fleksibel.

Untuk memberikan pemahaman yang lebih sistematis mengenai struktur data, **Tabel 4.2** menyajikan penjelasan lengkap dari seluruh **22 atribut** yang digunakan dalam penelitian ini, beserta deskripsi dan tipe datanya.

Tabel 4.2 Penjelasan Atribut Dataset

Atribut	Deskripsi	Tipe Data
<i>Parental Consent</i> (Persetujuan Orang Tua)	Menunjukkan apakah orang tua siswa memberikan persetujuan untuk partisipasi dalam penelitian atau survei.	Kategorikal ("Ya", "Tidak")
<i>Sex</i> (Jenis Kelamin)	Jenis kelamin siswa, yang berpengaruh terhadap kesejahteraan emosional	Kategorikal ("Laki-laki", "Perempuan")
<i>Grade</i> (Tingkat Kelas)	Kelas atau tingkat pendidikan siswa saat ini	Numerik (misalnya, 7, 8, 9, 10)
<i>Classes</i> (Mata Pelajaran)	Jenis mata pelajaran yang diambil oleh siswa	Numerik (jumlah mata pelajaran)
<i>Sleep</i> (Tidur)	Kualitas atau durasi tidur siswa, berhubungan dengan kesejahteraan emosional dan kesehatan mental	Numerik (jam tidur per malam)
<i>Homework</i> (Pekerjaan Rumah)	Waktu yang dihabiskan untuk mengerjakan pekerjaan rumah, berhubungan dengan stres akademik	Numerik (jam yang dihabiskan per minggu)
<i>Freetime</i> (Waktu Luang)	Jumlah waktu yang dimiliki siswa untuk kegiatan di luar sekolah	Numerik (jam per minggu)
<i>Work</i> (Pekerjaan)	Jika siswa memiliki pekerjaan paruh waktu atau tidak	Numerik (0 = Tidak, 1 = Ya)

<i>Extracurricular</i> (Kegiatan Ekstrakurikuler)	Partisipasi siswa dalam kegiatan ekstrakurikuler seperti olahraga atau seni.	Numerik (jumlah kegiatan ekstrakurikuler)
<i>Enjoyment Extracurricular</i> (Kesenangan dalam Kegiatan Ekstrakurikuler)	Seberapa menikmati siswa kegiatan ekstrakurikuler mereka	Numerik (skala 1-5)
<i>Extraversion</i> (Ekstraversi)	Tingkat ekstraversi siswa berdasarkan dimensi kepribadian	Numerik (skala 1-5)
<i>Family</i> (Keluarga)	Struktur dan kualitas hubungan keluarga siswa	Numerik (skala 1-5, dengan 1 = Tidak mendukung, 5 = Sangat mendukung)
<i>Strictness</i> (Kekerasan dalam Keluarga)	Tingkat ketegasan yang diterapkan oleh orang tua terhadap siswa.	Numerik (skala 1-5, dengan 1 = Tidak ketat, 5 = Sangat ketat)
<i>Friends</i> (Teman)	Jumlah atau kualitas hubungan pertemanan siswa.	Numerik (jumlah teman)
<i>Relationship</i> (Hubungan)	Hubungan siswa dengan teman sebaya atau pasangan.	Numerik (skala kepuasan hubungan)
<i>Loneliness</i> (Kesepiian)	Tingkat perasaan kesepian yang dialami siswa	Numerik (skala 1-5)
<i>Happiness</i> (Kebahagiaan)	Tingkat kebahagiaan yang dirasakan siswa	Numerik (skala 1-10)
<i>Happiness Comparison</i> (Perbandingan Kebahagiaan)	Perbandingan tingkat kebahagiaan siswa dengan teman-teman atau rata-rata populasi	Numerik (skala -5 sampai +5, dengan -5 = Jauh lebih tidak bahagia, +5 = Jauh lebih bahagia)

<i>Characterization Happiness</i> (Karakterisasi Kebahagiaan)	Bagaimana siswa menggambarkan kebahagiaan mereka	Numerik (skala 1-5, menggambarkan tingkat kebahagiaan)
<i>Characterization Depression</i> (Karakterisasi Depresi)	bagaimana siswa menggambarkan perasaan depresi atau kesedihan mereka	Numerik (skala 1-5, menggambarkan tingkat depresi)
<i>Mental Health</i> (Kesehatan Mental)	Status umum kesehatan mental siswa	Numerik (skala 1-5, dengan 1 = Buruk, 5 = Sangat Baik)
<i>SHC (Self-Reported Health Condition)</i>	Kondisi kesehatan yang dilaporkan sendiri oleh siswa, mencakup masalah fisik atau psikologis	Numerik (skala 1-5, dengan 1 = Sangat Buruk, 5 = Sangat Baik)

Secara umum, atribut dalam dataset dapat dikelompokkan ke dalam beberapa kategori utama. Pertama, atribut demografis dan akademik, seperti Sex, Grade, dan Classes, yang memberikan konteks dasar mengenai karakteristik siswa. Kedua, atribut kebiasaan dan aktivitas harian, seperti Sleep, Homework, Freetime, Work, dan Extracurricular, yang berpotensi memengaruhi tingkat stres dan keseimbangan kehidupan siswa. Ketiga, atribut psikososial, seperti Family, Friends, Relationship, dan Loneliness, yang merepresentasikan kualitas hubungan sosial dan dukungan emosional. Keempat, atribut persepsi emosional dan kesehatan, seperti Happiness, Mental Health, dan SHC, yang secara langsung berkaitan dengan variabel target dalam penelitian ini.

Seluruh atribut numerik pada dataset menggunakan skala pengukuran yang berbeda-beda, mulai dari skala jam, jumlah aktivitas, hingga skala Likert. Perbedaan skala ini memiliki implikasi langsung terhadap proses pemodelan, karena dapat memengaruhi kontribusi relatif setiap fitur dalam algoritma *machine learning*. Oleh karena itu, pada tahap selanjutnya dilakukan proses preprocessing untuk memastikan bahwa seluruh atribut berada pada skala yang sebanding dan dapat diproses secara optimal oleh model prediksi.

Dataset ini bersifat *cross-sectional*, yaitu data dikumpulkan pada satu titik waktu tertentu, sehingga tidak menangkap dinamika perubahan kondisi kesehatan mental siswa dari waktu ke waktu. Selain itu, data diperoleh melalui survei daring yang bergantung pada *self-report responden*, sehingga sangat dipengaruhi oleh persepsi subjektif siswa. Karakteristik ini menjadi salah satu keterbatasan penelitian, karena nilai yang dilaporkan dapat dipengaruhi oleh bias persepsi, kondisi emosional sesaat, maupun faktor sosial tertentu. Meskipun demikian, dataset ini tetap memiliki nilai penting karena merepresentasikan pengalaman subjektif siswa secara langsung, yang merupakan aspek krusial dalam kajian kesehatan mental.

Dengan karakteristik tersebut, dataset yang digunakan dalam penelitian ini dinilai memadai untuk tujuan pengembangan dan evaluasi model prediksi kesehatan mental siswa sekolah menengah. Pemahaman terhadap struktur dan sifat data ini menjadi dasar penting bagi tahapan preprocessing, pemodelan, serta interpretasi hasil yang dibahas pada subbab-subseksi berikutnya dalam Bab IV..

4.2. *Preprocessing Data*

Tahap preprocessing data dilakukan untuk memastikan bahwa data yang digunakan dalam pemodelan memiliki kualitas yang baik, konsisten, serta memenuhi prasyarat analisis regresi berbasis *machine learning*. Mengingat dataset yang digunakan bersifat survei daring dan mengandung atribut dengan skala serta tipe data yang beragam, maka proses preprocessing menjadi langkah krusial untuk meminimalkan bias, noise, dan potensi kesalahan dalam proses pembelajaran model.


Langkah pertama dalam preprocessing adalah konversi atribut kategorikal ke format numerik. Atribut Sex dikonversi menjadi representasi numerik, yaitu 0 untuk laki-laki dan 1 untuk perempuan. Konversi ini dilakukan agar atribut tersebut dapat diproses oleh algoritma XGBoost Regressor, yang membutuhkan input dalam bentuk numerik. Representasi biner dipilih karena atribut Sex hanya memiliki dua kategori, sehingga tidak memerlukan teknik encoding yang lebih kompleks seperti one-hot encoding.

Langkah kedua adalah penghapusan atribut statis atau tidak memiliki variasi nilai. Atribut Parental Consent dihapus dari dataset karena seluruh entri memiliki nilai yang sama ("Yes"). Atribut dengan variansi nol tidak memberikan informasi diskriminatif bagi model dan berpotensi menambah kompleksitas tanpa meningkatkan kemampuan prediksi. Oleh karena itu, penghapusan atribut ini bertujuan untuk menyederhanakan model dan meningkatkan efisiensi komputasi tanpa kehilangan informasi yang relevan.

Langkah selanjutnya adalah penghapusan atribut hasil akhir atau indikator turunan yang berpotensi menyebabkan data leakage. Beberapa kolom seperti

Happiness Comparison, Characterization Happiness, Characterization Depression, dan *Mental Health* dihapus karena atribut-atribut tersebut merepresentasikan penilaian akhir atau indikator yang secara konseptual berkaitan langsung dengan variabel target, yaitu *Self-Reported Health Condition (SHC)*. Keberadaan atribut-atribut tersebut dalam data latih berisiko memberikan informasi masa depan kepada model, sehingga dapat menghasilkan performa prediksi yang bias dan tidak realistis ketika diterapkan pada data baru. Dengan menghapus atribut-atribut tersebut, model dipaksa untuk belajar dari faktor-faktor dasar yang bersifat prediktif, bukan dari indikator hasil akhir.

Untuk memahami hubungan antar variabel yang tersisa dalam dataset, dilakukan analisis korelasi Pearson antara seluruh fitur numerik. Visualisasi hasil korelasi ditampilkan pada Gambar 4.1, yang menggambarkan kekuatan dan arah hubungan linier antar atribut dalam dataset.



Gambar 4. 1 Korelasi Pearson antara Semua Fitur

Hasil analisis korelasi menunjukkan bahwa variabel SHC memiliki korelasi yang sangat tinggi dengan variabel *Happiness* (nilai korelasi sebesar 0,88). Temuan ini mengindikasikan bahwa siswa dengan tingkat kebahagiaan subjektif yang lebih tinggi cenderung melaporkan kondisi kesehatan yang lebih baik. Hubungan ini bersifat intuitif dan sejalan dengan literatur kesehatan mental yang menyatakan bahwa kebahagiaan subjektif merupakan salah satu indikator utama kesejahteraan psikologis.

Selain itu, SHC juga menunjukkan korelasi positif dengan beberapa variabel psikososial lainnya, seperti *Enjoyment of Extracurricular*, *Extraversion*, *Family*, dan *Friends*. Hal ini mengindikasikan bahwa keterlibatan aktif dalam kegiatan

ekstrakurikuler, kepribadian yang lebih ekstrovert, serta dukungan sosial dari keluarga dan teman memiliki kontribusi positif terhadap persepsi kesehatan dan kesejahteraan emosional siswa. Sebaliknya, variabel Loneliness menunjukkan korelasi negatif dengan SHC, yang berarti semakin tinggi tingkat kesepian yang dirasakan siswa, semakin rendah kondisi kesehatan subjektif yang dilaporkan.

Temuan korelasi ini tidak digunakan sebagai dasar seleksi fitur secara langsung, melainkan sebagai analisis eksploratif untuk memahami struktur hubungan antar variabel dalam dataset. Hal ini penting karena korelasi yang tinggi tidak selalu berarti hubungan kausal, serta model XGBoost Regressor mampu menangkap hubungan nonlinier yang tidak tercermin dalam korelasi Pearson. Oleh karena itu, seluruh fitur yang telah lolos tahap preprocessing tetap dipertahankan dalam pemodelan untuk memberikan ruang bagi model dalam mempelajari pola yang lebih kompleks.

Secara keseluruhan, tahapan preprocessing yang dilakukan bertujuan untuk menghasilkan dataset yang bersih, informatif, dan bebas dari data leakage, sehingga proses pemodelan dan optimasi pada tahap selanjutnya dapat dilakukan secara adil dan valid. Dataset hasil preprocessing inilah yang kemudian digunakan sebagai input dalam pembangunan model baseline dan model dengan optimasi yang dibahas pada subbab berikutnya.

4.3. Pemodelan

Tahap pemodelan dalam penelitian ini dilakukan menggunakan XGBoost Regressor sebagai model utama. Pemodelan diawali dengan pembangunan model

baseline menggunakan konfigurasi default hyperparameter, yang kemudian dibandingkan dengan model XGBoost Regressor hasil optimasi menggunakan *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization*. Pendekatan ini bertujuan untuk mengevaluasi sejauh mana proses optimasi mampu meningkatkan kinerja prediksi model dibandingkan konfigurasi awal.

Pembagian data dilakukan dengan skema 80% data latih dan 20% data uji, yang bertujuan untuk memastikan bahwa evaluasi kinerja model mencerminkan kemampuan generalisasi terhadap data baru, bukan sekadar kemampuan menghafal pola pada data latih. Seluruh model dievaluasi menggunakan metrik MSE, RMSE, MAPE, dan R^2 , sebagaimana telah dijelaskan pada subbab evaluasi model.

4.3.1. Model Baseline XGBoost Regressor

Model baseline dibangun menggunakan XGBoost Regressor tanpa proses optimasi. Implementasi pemodelan baseline ditunjukkan pada Kode 1, yang mencakup proses pelatihan model, prediksi pada data uji, serta perhitungan metrik evaluasi.

Kode 1. Pemodelan *XGBoost Regressor*

```
# Membuat model XGBoost
xgboost_model = xgb.XGBRegressor(objective='reg:squarederror', random_state=42)

# Melatih model pada data latih
xgboost_model.fit(x_train, y_train)

# Memprediksi menggunakan data uji
y_pred = xgboost_model.predict(x_test)
```

```

# Hitung MSE
mse = mean_squared_error(y_test, y_pred)

# Hitung RMSE
rmse = np.sqrt(mse)

# Hitung MAPE
mape = np.mean(np.abs((y_test - y_pred) / y_test)) * 100
# Hitung R-Square
r2 = r2_score(y_test, y_pred)

# Tampilkan hasil
print("MSE : (mse:.4f)")
print("RMSE : (rmse:.4f)")
print("MAPE : (mape:.2f)%")
print("R² : (r2:.4f)")

```

Hasil evaluasi model baseline menunjukkan nilai **MSE sebesar 0.8893**, **RMSE sebesar 0.9430**, **MAPE sebesar 23.31%**, dan **R² sebesar 0.3841**. Nilai R² yang masih relatif rendah mengindikasikan bahwa model baseline hanya mampu menjelaskan sebagian variasi dalam data kesehatan mental siswa. Meskipun demikian, model ini tetap mampu menangkap pola umum dalam data, yang menunjukkan bahwa XGBoost memiliki potensi sebagai model prediktif pada domain ini.

Nilai error yang masih cukup besar dapat dipahami mengingat data kesehatan mental siswa bersifat **psikososial, subjektif, dan multidimensional**, sehingga hubungan antar variabel tidak sepenuhnya linier dan sulit dimodelkan menggunakan konfigurasi awal tanpa optimasi.

4.3.2. Optimasi Menggunakan Genetic Algorithm

Langkah selanjutnya adalah optimasi menggunakan *Genetic Algorithm*. Parameter utama GA yang digunakan ditunjukkan pada **Kode 2**, yang mencakup ukuran populasi ($POP_SIZE = 30$), jumlah generasi ($N_GENERATIONS = 50$), dan tingkat mutasi ($MUTATION_RATE = 0.1$). Parameter-parameter ini dipilih untuk menjaga keseimbangan antara eksplorasi ruang pencarian dan efisiensi komputasi.

Kode 2. Parameter utama GA.

```
# Genetic Algorithm Parameters
POP_SIZE = 30 # ukuran populasi
N_GENERATIONS = 50 # Jumlah generasi
MUTATION_RATE = 0.1 # Tingkat mutasi
```

Hasil optimasi GA menghasilkan kombinasi terbaik, yaitu ($'n_estimators': 355$, $'max_depth': 3$, $'learning_rate': 0.0206$, $'subsample': 0.544$). Implementasi parameter tersebut ke dalam model XGBoost Regressor (Kode 3) menghasilkan penurunan nilai **MSE menjadi 0.7180**, **RMSE menjadi 0.8473**, **MAPE menjadi 21.89%**, serta peningkatan **R^2 menjadi 0.5028**. Perbaikan ini menunjukkan bahwa GA mampu menemukan konfigurasi yang lebih sesuai dengan karakteristik data, sehingga model menjadi lebih seimbang antara kompleksitas dan kemampuan generalisasi.

Kode 3. *XGBoost Regressor* dengan best *hyperparameter* yang didapat dari GA

```
# Buat model dengan hyperparameter terbaik
optimized_model = xgb.XGBRegressor(
    n_estimators=best_params["n_estimators"],
    max_depth=best_params["max_depth"],
    learning_rate=best_params["learning_rate"],
    subsample=best_params["subsample"],
    objective='reg:squarederror',
```

```

random_state=42
)

# Latih model pada data latih
optimized_model.fit(x_train, y_train)

# Evaluasi pada data uji
y_pred = optimized_model.predict(x_test)

# Hitung MSE
mse = mean_squared_error(y_test, y_pred)

# Hitung RMSE
rmse = np.sqrt(mse)

# Hitung MAPE
mape = np.mean(np.abs((y_test - y_pred) / y_test)) * 100
# Hitung R-squared
r2 = r2_score(y_test, y_pred)

# Tampilkan hasil
print(f"MSE : {mse:.4f}")
print(f"RMSE : {rmse:.4f}")
print(f"MAPE : {mape:.2f}%")
print(f"R^2 : {r2:.4f}")

```

Secara kausal, peningkatan performa ini terjadi karena GA mengeksplorasi ruang secara global melalui mekanisme seleksi, *crossover*, dan mutasi. Mekanisme tersebut membantu model menghindari *overfitting* pada pola lokal yang tidak representatif dan meningkatkan kemampuan model dalam menangkap hubungan nonlinier antar variabel psikososial.

4.3.3. Optimasi Menggunakan *Particle Swarm Optimization*

Optimasi selanjutnya dilakukan menggunakan *Particle Swarm Optimization* dengan parameter utama sebagaimana ditunjukkan pada Kode 4. PSO menggunakan

30 partikel, 50 iterasi, serta parameter *inertia weight* dan koefisien akselerasi yang dirancang untuk menyeimbangkan eksplorasi dan eksploitasi ruang pencarian.

Kode 4. Parameter utama PSO

```
# Particle Swarm Optimization Parameters
POP_SIZE = 30 # Jumlah partikel dalam swarm
N_ITER = 50 # Jumlah iterasi
W = 0.7 # Inertia weight
C1 = 1.5 # Koefisien kognitif (personal best)
C2 = 1.5 # Koefisien sosial (global best)
```

Hasil optimasi PSO menghasilkan kombinasi terbaik, yaitu (*'n_estimators': 308, 'max_depth': 3, 'learning_rate': 0.01, 'subsample': 0.603*). Model XGBoost Regressor dengan parameter hasil PSO menghasilkan nilai **MSE sebesar 0.7025**, **RMSE sebesar 0.8381**, **MAPE sebesar 22.18%**, dan **R² sebesar 0.5135**. Dibandingkan GA, PSO memberikan nilai **MSE dan RMSE yang sedikit lebih rendah**, serta nilai **R² tertinggi** di antara seluruh metode optimasi yang diuji.

Secara sebab akibat, hal ini mengindikasikan bahwa mekanisme pergerakan partikel dalam PSO yang mengombinasikan pengalaman individu (*personal best*) dan pengalaman kolektif (*global best*), membantu model menemukan konfigurasi yang lebih representatif terhadap distribusi data secara keseluruhan. Karakteristik ini sangat relevan pada data kesehatan mental, di mana variasi antar individu cukup tinggi dan pola data tidak seragam.

4.3.4. Optimasi Menggunakan Bayesian Optimization

Optimasi terakhir dilakukan menggunakan *Bayesian Optimization* dengan parameter utama sebagaimana ditunjukkan pada **Kode 5**, termasuk jumlah evaluasi fungsi objektif ($N_CALLS = 30$) dan jumlah inialisasi acak ($N_RANDOM_STARTS = 10$). BO bekerja dengan memodelkan fungsi objektif menggunakan Gaussian Process dan memilih titik evaluasi berikutnya berdasarkan fungsi akuisisi.

Kode 5. *Bayesian Optimization*

```
# Bayesian Optimization Parameters
N_CALLS = 30 # Jumlah evaluasi fungsi objektif
N_RANDOM_STARTS = 10 # Jumlah inialisasi acak sebelum model GP
RANDOM_STATE = 42 # Reproducibility
```

Hasil optimasi BO menghasilkan kombinasi terbaik yaitu (`'n_estimators': 397`, `'max_depth': 3`, `'learning_rate': 0.108`, `'subsample': 0.710`). Model hasil BO menghasilkan nilai **MSE sebesar 0.7485**, **RMSE sebesar 0.8652**, **MAPE sebesar 22.43%**, dan **R² sebesar 0.4816**. Meskipun nilai MSE sedikit lebih tinggi dibanding GA dan PSO, BO menunjukkan performa yang kompetitif dalam menekan kesalahan relatif, yang tercermin dari nilai MAPE yang tetap rendah.

Keunggulan BO secara kausal dapat dijelaskan oleh kemampuannya memodelkan fungsi objektif secara probabilistik, sehingga pencarian menjadi lebih terarah dan efisien pada ruang pencarian yang kompleks dan tidak konveks. Pendekatan ini sangat relevan untuk data psikososial yang memiliki pola nonlinier dan tingkat ketidakpastian yang tinggi.

4.3.5. Analisis Perbandingan Hasil Pemodelan

Perbandingan hasil evaluasi seluruh model disajikan pada **Tabel 4.3**.

Tabel 4. 3 Perbandingan Hasil Evaluasi Model

Model	MSE	RMSE	MAPE (%)	R ²
Baseline	0.8893	0.9430	23.31	0.3841
GA	0.7180	0.8473	21.89	0.5028
PSO	0.7025	0.8381	22.18	0.5135
BO	0.7485	0.8652	22.43	0.4816

Berdasarkan Tabel 4.3, terlihat bahwa **tidak terdapat satu metode optimasi yang unggul secara absolut pada seluruh metrik evaluasi**. GA menunjukkan kemampuan yang baik dalam menekan kesalahan prediksi absolut, PSO memberikan keseimbangan terbaik antara akurasi dan stabilitas dengan nilai R² tertinggi, sementara BO unggul dalam efisiensi pencarian dan kesalahan relatif.

Variasi performa ini berkaitan erat dengan karakteristik data kesehatan mental siswa, yang dipengaruhi oleh faktor-faktor psikososial seperti *Happiness*, *Loneliness*, *Family*, dan *Friends*. Pada kondisi emosional ekstrem, pola data menjadi lebih sulit dipelajari oleh model, sehingga error prediksi meningkat. Sebaliknya, pada kondisi data yang lebih stabil, model mampu menghasilkan prediksi yang lebih akurat. Hal ini menjelaskan secara kausal mengapa optimasi mampu meningkatkan performa model dibandingkan baseline.

Dari perspektif implementasi praktis, PSO menawarkan kompromi terbaik antara akurasi, stabilitas, dan efisiensi komputasi. Oleh karena itu, pemilihan metode

optimasi dalam lingkungan pendidikan tidak hanya perlu mempertimbangkan akurasi prediksi, tetapi juga kompleksitas implementasi dan sumber daya komputasi yang tersedia.

4.4. Analisis Komparasi

Analisis komparatif dilakukan untuk menempatkan hasil penelitian ini dalam konteks penelitian terdahulu, sekaligus mengkaji kesesuaian, perbedaan, dan perluasan perspektif terhadap temuan yang telah dilaporkan sebelumnya. Pendekatan ini penting untuk memastikan bahwa peningkatan performa model yang diperoleh tidak hanya bersifat lokal terhadap dataset yang digunakan, tetapi juga memiliki relevansi ilmiah yang lebih luas serta dapat dimaknai secara kontekstual sesuai karakteristik domain kesehatan mental siswa.

Penelitian oleh Chung dan Teo (2023) menunjukkan bahwa algoritma berbasis *ensemble learning*, khususnya *Gradient Boosting*, mampu mencapai tingkat akurasi tertinggi sebesar 88,80% dalam prediksi kesehatan mental mahasiswa. Temuan ini menegaskan keunggulan pendekatan *ensemble* dalam menangani data psikologis yang kompleks. Namun, penelitian tersebut juga mengindikasikan adanya keterbatasan model dalam menangkap variabilitas emosional yang tinggi. Persepsi ini sejalan dengan hasil penelitian ini, di mana model baseline XGBoost menunjukkan performa awal yang cukup baik, tetapi masih menghasilkan error yang relatif besar pada kondisi emosional ekstrem. Kesamaan ini menunjukkan bahwa baik pada populasi mahasiswa maupun siswa sekolah menengah, data kesehatan mental memiliki karakteristik yang serupa, yaitu bersifat subjektif, dinamis, dan

dipengaruhi oleh interaksi kompleks faktor psikososial. Dengan demikian, optimasi dalam penelitian ini dapat dipandang sebagai respons metodologis terhadap keterbatasan yang juga teridentifikasi dalam penelitian terdahulu.

Selanjutnya, Ayodele et al. (2024) melaporkan bahwa penerapan optimasi metaheuristik, khususnya *Genetic Algorithm*, mampu meningkatkan performa model prediksi secara signifikan dengan capaian koefisien determinasi (R^2) yang sangat tinggi. Persepsi hasil penelitian tersebut menekankan keberhasilan optimasi dari sisi peningkatan akurasi numerik. Namun, penelitian tersebut belum secara eksplisit membahas hubungan antara karakteristik data dan kondisi di mana optimasi bekerja paling efektif. Berbeda dengan pendekatan tersebut, penelitian ini tidak hanya menyoroti peningkatan performa model, tetapi juga mengaitkannya dengan karakter variabel dominan seperti loneliness, family support, dan happiness yang memiliki korelasi kuat terhadap Self-Reported Health Condition (SHC). Perbedaan fokus ini mencerminkan perbedaan persepsi terhadap makna peningkatan performa, di mana penelitian ini menekankan bahwa efektivitas optimasi tidak dapat dilepaskan dari pemahaman konteks data dan sifat psikososial yang melatarbelakanginya.

Penelitian oleh Shen (2023), yang menggunakan dataset yang sama dengan penelitian ini, melaporkan nilai R^2 sekitar 0,51 menggunakan pendekatan *Neural Network* dan Regresi Linier. Jika dilihat secara sekilas, capaian tersebut tampak sebanding atau bahkan lebih baik dibandingkan sebagian hasil dalam penelitian ini. Namun, perbedaan persepsi terhadap hasil tersebut dapat dijelaskan secara kausal melalui perbedaan tujuan analisis dan kompleksitas model yang digunakan. Pendekatan *Neural Network* dan regresi linier cenderung bekerja optimal pada

kondisi tertentu, sedangkan data kesehatan mental siswa bersifat heterogen, terbatas, dan sangat dipengaruhi oleh faktor subjektif. Oleh karena itu, capaian R^2 yang moderat dalam penelitian ini tidak dapat diartikan sebagai kelemahan model, melainkan sebagai refleksi realistis dari kompleksitas domain yang diteliti. Hal ini justru memperkuat argumen bahwa penggunaan XGBoost dengan optimasi merupakan pendekatan yang lebih proporsional dan stabil dalam konteks data pendidikan.

Jika dibandingkan dengan penelitian yang menggunakan metode regresi linier atau algoritma konvensional, hasil penelitian ini menunjukkan peningkatan performa yang lebih konsisten dalam menangani interaksi nonlinier antar variabel psikososial. Variabel seperti hubungan keluarga, pertemanan, dan kesepian tidak bekerja secara independen, melainkan saling memperkuat atau melemahkan satu sama lain. Model *ensemble* seperti XGBoost lebih adaptif terhadap pola interaksi semacam ini, sehingga perbedaan performa dengan pendekatan linier dapat dipahami secara metodologis, bukan semata-mata sebagai perbedaan nilai akurasi.

Dari sudut pandang akurasi dan proses komputasi, beberapa penelitian terdahulu menunjukkan bahwa metode dengan akurasi tinggi sering kali disertai dengan kompleksitas komputasi yang lebih besar. Persepsi ini konsisten dengan hasil penelitian ini, di mana *Bayesian Optimization* memberikan akurasi relatif yang kompetitif, tetapi memerlukan waktu komputasi yang lebih tinggi. Sebaliknya, *Particle Swarm Optimization* menawarkan keseimbangan yang lebih baik antara akurasi dan efisiensi komputasi. Temuan ini menegaskan bahwa pemilihan metode optimasi tidak dapat didasarkan pada akurasi semata, melainkan harus

mempertimbangkan konteks implementasi dan ketersediaan sumber daya. Dalam lingkungan sekolah yang memiliki keterbatasan sumber daya teknis, metode yang efisien namun cukup akurat menjadi lebih realistis untuk diterapkan.

Secara keseluruhan, analisis komparatif ini menunjukkan bahwa hasil penelitian ini tidak bertentangan dengan penelitian terdahulu, melainkan memperluas dan memperkaya perspektif yang ada. Jika sebagian penelitian sebelumnya lebih menekankan pada capaian akurasi numerik, maka penelitian ini menambahkan dimensi analisis sebab-akibat dan konteks domain pendidikan. Kontribusi utama penelitian ini tidak hanya terletak pada peningkatan performa model prediksi, tetapi juga pada penyediaan kerangka analitis yang mengaitkan algoritma, metode optimasi, dan karakteristik data psikososial secara terpadu. Dengan demikian, penelitian ini bersifat tidak hanya teknis, tetapi juga kontekstual dan aplikatif.

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, dapat ditarik beberapa kesimpulan sebagai berikut.

1. Penelitian ini membuktikan bahwa penerapan optimasi pada *XGBoost Regressor* mampu meningkatkan performa model prediksi kesehatan mental siswa secara signifikan dibandingkan dengan model baseline. Penurunan nilai MSE, RMSE, dan MAPE serta peningkatan nilai R^2 pada seluruh metode optimasi (*Genetic Algorithm*, *Particle Swarm Optimization*, dan Bayesian Optimization) menunjukkan bahwa konfigurasi yang tepat berperan langsung dalam meningkatkan kemampuan generalisasi model. Temuan ini menegaskan bahwa permasalahan utama dalam prediksi kesehatan mental tidak hanya terletak pada pemilihan algoritma, tetapi pada proses pengaturan dan optimasi algoritma tersebut.
2. Peningkatan performa yang diperoleh bersifat substantif dan konsisten di berbagai metrik evaluasi. Konsistensi penurunan error pada data uji menunjukkan bahwa model hasil optimasi tidak sekadar menyesuaikan diri terhadap data latih, tetapi memiliki stabilitas prediksi yang lebih baik. Dengan demikian, model yang dihasilkan memiliki potensi untuk digunakan sebagai alat bantu prediksi risiko kesehatan mental siswa, khususnya dalam konteks deteksi dini.

3. Meskipun terjadi peningkatan performa, hasil penelitian ini menunjukkan bahwa capaian model belum mencapai tingkat optimal secara absolut. Nilai error yang masih relatif moderat serta variasi performa antar metode optimasi mengindikasikan bahwa keterbatasan dataset, jumlah sampel, dan sifat data yang bersifat subjektif (*self-reported*) turut memengaruhi kinerja model. Oleh karena itu, keterbatasan hasil bukan semata-mata mencerminkan kelemahan metode, melainkan konsekuensi dari kompleksitas domain kesehatan mental yang diteliti.
4. Perbandingan antara *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization* menunjukkan bahwa tidak terdapat satu metode yang unggul secara mutlak pada seluruh aspek evaluasi. *Bayesian Optimization* cenderung memberikan akurasi relatif yang baik dengan konsekuensi waktu komputasi yang lebih tinggi, *Particle Swarm Optimization* menawarkan keseimbangan antara akurasi dan efisiensi, sedangkan *Genetic Algorithm* menunjukkan performa yang stabil. Temuan ini menegaskan bahwa pemilihan metode optimasi sebaiknya disesuaikan dengan tujuan penggunaan model dan ketersediaan sumber daya, bukan semata-mata berdasarkan nilai error terendah.
5. Analisis korelasi antar variabel menunjukkan bahwa faktor-faktor seperti kebahagiaan subjektif, dukungan sosial keluarga dan teman, serta tingkat kesepian memiliki hubungan yang kuat dengan kondisi kesehatan mental siswa. Hal ini memberikan penjelasan kausal mengapa model mampu melakukan prediksi dengan cukup baik, karena variabel-variabel tersebut

relevan secara psikologis. Dengan demikian, hasil penelitian ini tidak hanya sah secara statistik, tetapi juga memiliki dasar teoritis yang kuat.

6. Secara keseluruhan, hasil penelitian ini layak dijadikan dasar awal dalam pengembangan sistem prediksi kesehatan mental siswa. Namun, model yang dihasilkan belum dapat dijadikan satu-satunya dasar pengambilan keputusan tanpa dukungan analisis lanjutan dan validasi kontekstual. Keterbatasan pada interpretasi, eksplorasi hubungan sebab-akibat, serta variasi kondisi data menjadi dasar perlunya pengembangan penelitian lebih lanjut.

5.2. Saran


Berdasarkan keterbatasan dan temuan dalam penelitian ini, beberapa saran berikut diajukan untuk penelitian lanjutan maupun implementasi praktis.

1. Penelitian selanjutnya disarankan untuk memperdalam analisis hubungan sebab-akibat antar variabel yang memengaruhi kesehatan mental siswa. Analisis tidak hanya difokuskan pada penurunan nilai MSE, RMSE, MAPE, atau R^2 , tetapi juga pada pemahaman mengapa variabel seperti *sleep*, *loneliness*, *family support*, dan *friends* memberikan kontribusi besar terhadap performa model. Pendekatan interpretabilitas model seperti *feature importance*, SHAP, atau *partial dependence plot* dapat digunakan untuk mengurangi sifat *black box* model.
2. Untuk mengidentifikasi kondisi optimal penggunaan metode optimasi, penelitian selanjutnya disarankan melakukan eksperimen berbasis skenario, misalnya dengan mengelompokkan data berdasarkan tingkat stres, dukungan

sosial, atau kebahagiaan. Dengan pendekatan ini, dapat dianalisis secara lebih spesifik pada kondisi data seperti apa *Genetic Algorithm*, *Particle Swarm Optimization*, dan *Bayesian Optimization* bekerja paling efektif.

3. Penelitian lanjutan disarankan memperluas perbandingan model dan metode optimasi, tidak hanya terbatas pada XGBoost dengan GA, PSO, dan BO, tetapi juga melibatkan algoritma lain seperti *Random Forest*, *LightGBM*, atau *Neural Network* dengan teknik optimasi yang berbeda. Hal ini penting untuk memastikan bahwa peningkatan performa benar-benar berasal dari keunggulan metode, bukan semata karakteristik dataset.
4. Dari sisi evaluasi, penelitian selanjutnya perlu mengaitkan pemilihan metrik evaluasi dengan konteks domain kesehatan mental. Analisis dampak praktis dari kesalahan prediksi besar (*outlier*) terhadap risiko salah deteksi siswa perlu dikaji, sehingga evaluasi model tidak hanya bersifat teknis, tetapi juga bermakna secara psikologis dan edukatif.
5. Penyajian hasil penelitian ke depan disarankan dilakukan secara lebih konsisten dalam bentuk tabel komparatif dan visualisasi grafik, sehingga pola peningkatan atau penurunan performa model dapat dianalisis secara visual dan dijadikan dasar argumen ilmiah yang lebih kuat.
6. Untuk pengembangan praktis, hasil penelitian ini sebaiknya diarahkan pada implementasi sistem pendukung keputusan di lingkungan sekolah, misalnya sebagai sistem peringatan dini bagi guru bimbingan konseling atau konselor sekolah. Penelitian lanjutan dapat mengkaji bagaimana output prediksi diterjemahkan menjadi rekomendasi intervensi yang aplikatif, sehingga

model tidak hanya akurat secara statistik, tetapi juga memberikan manfaat nyata dalam upaya peningkatan kesehatan mental siswa



DAFTAR PUSTAKA

- Ahamad, G. N., Shafiullah, Fatima, H., Imdadullah, Zakariya, S. M., Abbas, M., Alqahtani, M. S., & Usman, M. (2023). Influence of Optimal Hyperparameters on the Performance of *Machine learning* Algorithms for Predicting Heart Disease. *Processes*, *11*(3), 734. <https://doi.org/10.3390/pr11030734>
- Ali, Y. A., Awwad, E. M., Al-Razgan, M., & Maarouf, A. (2023). Hyperparameter Search for *Machine learning* Algorithms for Optimizing the Computational Complexity. *Processes*, *11*(2). <https://doi.org/10.3390/pr11020349>
- Amirhosseini, M. H., Ayodele, A. L., & Karami, A. (2024). Prediction of Depression Severity and Personalised Risk Factors Using *Machine learning* on Multimodal Data. *IEEE*. <https://doi.org/https://doi.org/10.1109/IS61756.2024.10705185>
- Ayodele, A., Adetunla, A., & Akinlabi, E. (2024). Prediction of Depression Severity and Personalised Risk Factors Using *Machine learning* on Multimodal Data. *International Journal of Online and Biomedical Engineering*, *20*(9), 130–143. <https://doi.org/10.3991/ijoe.v20i09.47581>
- Bajpai, P. (2010). *Genetic Algorithm*-an Approach to Solve Global Optimization Problems. *Indian Journal of Computer Science and Engineering*, *1*, 199–206.
- Bintoro, panji, Ratnasari, Wihardjo, E., Putri, I. P., & Asari, A. (2024). *Pengantar Machine learning* (A. Asari, Ed.; Vol. 127). MAFY MEDIA LITERASI INDONESIA. <https://repository.um.ac.id/5619/1/fullteks.pdf>
- Bokonda, P. L., Ouazzani-Touhami, K., & Souissi, N. (2020). Predictive analysis using *machine learning*: Review of trends and methods. *2020 International*

- Symposium on Advanced Electrical and Communication Technologies (ISAECT)*, 1–6. <https://doi.org/10.1109/ISAECT50560.2020.9523703>
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chung, J., & Teo, J. (2023). Single classifier vs. ensemble machine learning approaches for mental health prediction. *Brain Informatics*, 10(1). <https://doi.org/10.1186/s40708-022-00180-6>
- Gil, M., Kim, S.-S., & Jeong Min, E. (2022). Machine learning models for predicting risk of depression in Korean college students: Identifying family and individual factors. <https://doi.org/https://doi.org/10.3389/fpubh.2022.1023010>
- Gupta, P., Maji, S., & Mehra, R. (2022). Predictive Modeling of Stress in the Healthcare Industry during COVID-19: A Novel Approach Using XGBoost, SHAP Values, and Tree Explainer. *International Journal of Decision Support System Technology*, 15(1). <https://doi.org/10.4018/IJDSST.315758>
- Hossain, S., Miah, M. N. I., Rana, M. S., Hossain, M. S., Bhowmik, P. K., Rahman, M. K., & akter, R. (2024). Analyzing Trends And Determinants Of Leading Causes Of Death In The Usa: A Data-Driven Approach. *The American Journal of Medical Sciences and Pharmaceutical Research*, 06(12), 54–71. <https://doi.org/10.37547/TAJMSPR/Volume06Issue12-07>

- Ismail, Z., & Irhamah. (2008). Adaptive permutation-based *Genetic Algorithm* for solving VRP with stochastic demands. *Journal of Applied Sciences*, 8(18), 3228–3234. <https://doi.org/10.3923/jas.2008.3228.3234>
- Jones, S. E., Ethier, K. A., Hertz, M., Degue, S., Vi, :, Le, D., Thornton, J., Lim, ; Connie, Dittus, P. J., & Geda, S. (2022). *Mental Health, Suicidality, and Connectedness Among High School Students During the COVID-19 Pandemic — Adolescent Behaviors and Experiences Survey, United States, January–June 2021*. <https://doi.org/http://dx.doi.org/10.15585/mmwr.su7103a3>
- Karki, A., Thapa, B., Pradhan, P. M. S., & Basel, P. (2022). Depression, anxiety and stress among high school students: A cross-sectional study in an urban municipality of Kathmandu, Nepal. *PLOS Global Public Health*, 2(5), e0000516. <https://doi.org/10.1371/journal.pgph.0000516>
- Kennedy, J., & Eberhart, R. (1995). *Particle Swarm Optimization*. *Proceedings of ICNN'95 - International Conference on Neural Networks*, 1942–1948. <https://doi.org/10.1109/ICNN.1995.488968>
- Khoo, L. S., Lim, M. K., Chong, C. Y., & McNaney, R. (2024). *Machine learning for Multimodal Mental Health Detection: A Systematic Review of Passive Sensing Approaches*. *Sensors*, 24(2), 348. <https://doi.org/10.3390/s24020348>
- Kittleson, M. J. (2019). Mental Health v. Mental Illness: A Health Education Perspective. In *American Journal of Health Education* (Vol. 50, Issue 4, pp. 210–212). Routledge. <https://doi.org/10.1080/19325037.2019.1616011>
- Lewin, G., Abakasanga, E., Titcombe, I., Cosma, G., & Gangadharan, S. (2025). *Artificial Intelligence-enabled predictive modelling in psychiatry: overview of*

- machine learning* applications in mental health research. *BJPsych Advances*, 1–7. <https://doi.org/10.1192/bja.2025.10133>
- Li, C., Jiang, J., Zhao, Y., Li, R., Wang, E., Zhang, X., & Zhao, K. (2022). *Genetic Algorithm* based hyper-parameters optimization for transfer convolutional neural network. In R. Tiwari (Ed.), *International Conference on Advanced Algorithms and Neural Networks (AANN 2022)* (Vol. 12285, p. 1228512). SPIE. <https://doi.org/10.1117/12.2637170>
- Liu, J. L., Wang, C., Do, K. A., & Bali, D. (2022). Asian American adolescents' mental health literacy and beliefs about helpful strategies to address mental health challenges at school. *Psychology in the Schools*, 59(10), 2062–2084. <https://doi.org/10.1002/pits.22655>
- McKee, C., & Breslin, M. (2022). Whose Responsibility is it Anyway? Pupil Mental Health in a Scottish Secondary School. *Scottish Educational Review*, 54(1), 49–69. <https://doi.org/10.1163/27730840-54010004>
- Mullick, T., Radovic, A., Shaaban, S., & Doryab, A. (2022). Predicting Depression in Adolescents Using Mobile and Wearable Sensors: Multimodal *Machine learning*-Based Exploratory Study. *JMIR Formative Research*, 6(6). <https://doi.org/10.2196/35807>
- Papazoglou, G., & Biskas, P. (2023). Review and Comparison of *Genetic Algorithm* and *Particle Swarm Optimization* in the Optimal Power Flow Problem. *Energies*, 16(3), 1152. <https://doi.org/10.3390/en16031152>
- Patel, V., Flisher, A. J., Nikapota, A., & Malhotra, S. (2008). Promoting child and adolescent mental health in low and middle income countries. In *Journal of*

- Child Psychology and Psychiatry and Allied Disciplines* (Vol. 49, Issue 3, pp. 313–334). <https://doi.org/10.1111/j.1469-7610.2007.01824.x>
- Poli, R., Kennedy, J., & Blackwell, T. (2007). *Particle Swarm Optimization*. *Swarm Intelligence*, 1(1), 33–57. <https://doi.org/10.1007/s11721-007-0002-0>
- Putra, B. S. C., Tahyudin, I., Kusuma, B. A., & Isnaini, K. N. (2024). Efektivitas Algoritma *Random Forest*, *XGBoost*, dan *Logistic Regression* dalam Prediksi Penyakit Paru-paru. *Techno.Com*, 23(4), 909–922. <https://doi.org/10.62411/tc.v23i4.11705>
- Riosatria, Hairani, H., Anggrawan, A., & Syahrir, M. (2024). Enhancing Mental Illness Predictions Analyzing Trends Using Multiple Linear Regression and *Neural Network Backpropagation*. *International Journal of Engineering and Computer Science Applications (IJECSA)*, 3(2), 61–70. <https://doi.org/10.30812/ijecea.v3i2.4391>
- Shahvaroughi Farahani, M., & Esfahani, A. (2022). Prediction Of Daily New Death Cases Due To Covid-19 Using Artificial Neural Networks And *Genetic Algorithm*. *JAISIS*. <https://doi.org/10.22034/JAISIS.2022.327647.1042>
- Shen, Y. (2023). High School Emotional Well-Being: Identifying Factors And Creating A Working Model For Prediction. *Journal of Student Research*. <https://doi.org/10.47611/jsrhs.v12i3.4743>
- Shi, Y., & Eberhart, R. (1998). A modified particle swarm optimizer. *1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence (Cat. No.98TH8360)*, 69–73. <https://doi.org/10.1109/ICEC.1998.699146>

- Śniadach, J., Szymkowiak, S., Osip, P., & Waszkiewicz, N. (2021). Increased depression and anxiety disorders during the covid-19 pandemic in children and adolescents: A literature review. In *Life* (Vol. 11, Issue 11). MDPI. <https://doi.org/10.3390/life11111188>
- Suratno, T., & Rarasati, N. (2019). Optimization of *Genetic Algorithm* for Implementation Designing and Modeling in Academic Scheduling. *EKSAKTA*, 20. <https://doi.org/10.24036/eksakta/vol20-iss01/166>
- Thakkar, A., Gupta, A., & De Sousa, A. (2024). *Artificial Intelligence* in positive mental health: a narrative review. *Frontiers in Digital Health*, 6. <https://doi.org/10.3389/fdgth.2024.1280235>
- Venrooij, L. T. van. (2024). *Portal to care: general practitioners' decision-making on child and youth mental health problems and the influence of their (lived) experience* [Leiden University Medical Center (LUMC)]. <https://hdl.handle.net/1887/3736110>
- Wahdi, A. E., Setyawan, A., Putri, Y. A., Wilopo, S. A., Erskine, H. E., Wallis, K., Blum, R., & Fine, S. (2023). *I-NAMHS: Indonesia-National Adolescent Mental Health Survey*. <https://qcmhr.org/outputs/reports/12-i-namhs-report-bahasa-indonesia>
- Wang, L. (2025). Analysis and Prediction of College Students' Hidden Mental Health Status Based on Data Mining. *Proceedings of the 2025 International Conference on Big Data and Informatization Education*, 351–356. <https://doi.org/10.1145/3729605.3729667>

- Yang, L., & Shami, A. (2020). On hyperparameter optimization of *machine learning* algorithms: Theory and practice. *Neurocomputing*, 415, 295–316. <https://doi.org/10.1016/j.neucom.2020.07.061>
- Zhai, Y., Zhang, Y., Chu, Z., Geng, B., Almaawali, M., Fulmer, R., Lin, Y. D., Xu, Z., Daniels, A. D., Liu, Y., Chen, Q., & Du, X. (2025). *Machine learning* predictive models to guide prevention and intervention allocation for anxiety and depressive disorders among college students. *Journal of Counseling & Development*, 103(1), 110–125. <https://doi.org/10.1002/jcad.12543>
- Zulfiqar, M., Gamage, K. A. A., Kamran, M., & Rasheed, M. B. (2022). Hyperparameter Optimization of Bayesian Neural Network Using Bayesian Optimization and Intelligent Feature Engineering for Load Forecasting. *Sensors*, 22(12), 4446. <https://doi.org/10.3390/s22124446>

LAMPIRAN

