

**KLASIFIKASI KESEHATAN MENTAL PADA *IMBALANCED DATA*  
MENGUNAKAN *RANDOM FOREST* DAN SMOTE**

**SKRIPSI**

Oleh :  
**UMMI KUNHAYATI**  
**NIM. 210605110011**



**PROGRAM STUDI TEKNIK INFORMATIKA  
FAKULTAS SAINS DAN TEKNOLOGI  
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM  
MALANG  
2025**

**KLASIFIKASI KESEHATAN MENTAL PADA *IMBALANCED DATA*  
MENGUNAKAN *RANDOM FOREST* DAN SMOTE**

**SKRIPSI**

Diajukan kepada:  
Universitas Islam Negeri Maulana Malik Ibrahim Malang  
Untuk memenuhi Salah Satu Persyaratan dalam  
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh :  
**UMMI KUNHAYATI**  
**NIM. 210605110011**

**PROGRAM STUDI TEKNIK INFORMATIKA  
FAKULTAS SAINS DAN TEKNOLOGI  
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM  
MALANG  
2025**

## HALAMAN PERSETUJUAN

### KLASIFIKASI KESEHATAN MENTAL PADA *IMBALANCED DATA* MENGUNAKAN *RANDOM FOREST* DAN *SMOTE*

#### SKRIPSI

Oleh :

**UMMI KUNHAYATI**  
**NIM. 210605110011**

Telah Diperiksa dan Disetujui untuk Diuji:  
Tanggal: 16 Juni 2025

Pembimbing I,



**Prof. Dr. Suhartono, M.Kom**  
NIP. 19680519 200312 1 001

Pembimbing II,

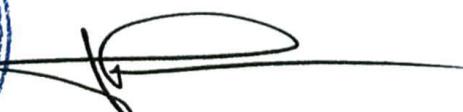


**Dr. M. Imamudin Lc, MA**  
NIP. 19740602 200901 1 010

Mengetahui,

Ketua Program Studi Teknik Informatika  
Fakultas Sains dan Teknologi

Universitas Islam Negeri Maulana Malik Ibrahim Malang



**Dr. Ir. Fachrul Kurniawan, M.MT., IPU**  
NIP. 19771020 200912 1 001



## PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Ummi Kunhayati

NIM : 210605110011

Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika

Judul Skripsi : Klasifikasi Kesehatan Mental pada *Imbalanced Data*  
Menggunakan *Random Forest* dan SMOTE

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 21 Juni 2025

Yang membuat pernyataan,



Ummi Kunhayati

NIM. 210605110011

## **MOTTO**

*“Janganlah kamu berduka cita, sesungguhnya Allah selalu bersama kita.”*

(Qs. At-Taubah: 40)

## **HALAMAN PERSEMBAHAN**

Rasa syukur yang kepada Allah SWT, atas rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi ini. Dengan penuh rasa hormat dan cinta,

karya ini penulis persembahkan kepada:

Kedua orang tua tercinta, Bapak Nur Khozin dan Ibu Siti Insana atas cinta dan doa yang tiada henti.

Dosen pembimbing dan teman-teman seperjuangan atas ilmu, bimbingan, dan kebersamaan yang berarti selama proses ini.

Kepada diri sendiri, terima kasih telah bertahan meski penuh rintangan. Semoga karya ini menjadi awal yang baik dan menjadi manfaat bagi banyak pihak.

## KATA PENGANTAR

*Assalamu 'alaikum warahmatullahi wabarakatuh*

Segala puji bagi Allah SWT, yang telah melimpahkan rahmat dan hidayah-Nya, penulis akhirnya dapat menyelesaikan skripsi ini dengan judul "Klasifikasi Kesehatan Mental pada *Imbalanced Data* Menggunakan *Random Forest* dan SMOTE" dengan baik dan lancar. Shalawat dan salam semoga senantiasa tercurah kepada Nabi Muhammad SAW, yang telah membawa umat manusia dari kegelapan menuju cahaya Islam yang terang benderang.

Skripsi ini merupakan hasil dari perjalanan panjang dalam memenuhi tugas akhir perkuliahan sebagai syarat kelulusan Program Studi Teknik Informatika di UIN Maulana Malik Ibrahim Malang. Dalam proses ini, banyak pihak yang telah membantu penulis dalam menyusun dan menyelesaikan tugas ini. Oleh karena itu, penulis mengucapkan terima kasih yang tulus kepada:

1. Prof. Dr. M. Zainuddin, M.A., selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Prof. Dr. Hj. Sri Harini, M.Si., selaku dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Dr. Ir. Fachrul Kurniawan, M.MT., IPU., selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang. viii

4. Prof. Dr. Suhartono, M.Kom, selaku Dosen Pembimbing I yang telah membimbing penulis sepanjang perjalanan skripsi ini. Bimbingan, arahan, dan dukungan yang diberikan.
5. Dr. M. Imamudin Lc, MA, selaku Dosen Pembimbing II yang membimbing dan memberikan arahan kepada penulis dalam proses penulisan skripsi dan penulisan integrasi islam.
6. Dr. Irwan Budi Santoso, M.Kom, selaku Dosen Penguji I dan Khadijah F.H Holle, M.Kom, selaku Dosen Penguji II yang telah menguji dan memberikan masukan kepada penulis sehingga penulis dapat menghasilkan skripsi yang baik.
7. Segenap Dosen, Admin, Laboran dan Jajaran Staff Program Studi Teknik Informatika yang telah memberikan ilmu, dukungan, dan bimbingan yang sangat berarti bagi penulis selama menjalani studi di Universitas Islam Maulana Malik Ibrahim Malang.
8. Kedua orang tua tercinta, Bapak Nur Khozin dan Ibu Siti Insana yang telah memberi cinta, doa, dan dukungan yang tak terhingga. Adek Nilna Naura Faradis yang imut dan menggemaskan. Mereka adalah sumber kekuatan, motivasi, dan teladan yang selalu memberikan semangat di setiap langkah perjalanan ini. Terima kasih telah menjadi tempat penulis untuk selalu kembali, memberikan doa yang tiada henti, dan memberikan segala yang terbaik demi masa depan penulis.

9. Pengasuh dan santri Pondok Pesantren Al-Hikmah Al-Fathimiyyah yang telah memberikan kesempatan kepada penulis untuk melakukan penelitian dan kontribusinya dalam mengisi kuesioner dari penulils.
10. Teman-teman seperjuangan dan sepembimbingan, Puja, Otul, dan Sita yang selalu ada di setiap langkah perjalanan ini. Terima kasih atas dukungan, semangat, dan kebersamaan yang selalu diberikan.
11. Teman-teman “bismillah gak boyong yuk!” yang telah menemani penulis melalui setiap proses penyusunan skripsi ini. Terima kasih atas kebersamaan yang penuh dengan semangat, motivasi, dan saling mendukung.
12. Teman-teman “anak baik” yang telah menjadi bagian penting dalam perjalanan penulis selama perjalanan kuliah ini. Terima kasih atas kebersamaan, semangat, dan dukungan yang selalu kalian berikan.
13. Teman-teman Angkatan 2021 “ASTER” yang sudah kebersamai penulis sepanjang perjalanan perkuliahan ini.
14. Terakhir, terimakasih untuk diri sendiri, karena sudah mampu berjuang dan bertahan sejauh ini. Semoga perjalanan ini menjadi pelajaran berharga yang akan terus membawa penulis ke arah yang lebih baik, dan semoga pencapaian ini menjadi awal dari perjalanan yang lebih indah dan penuh makna di masa depan. Sebagai penutup, penulis menyadari bahwa skripsi ini bukanlah hasil kerja keras penulis seorang diri, melainkan hasil dukungan, doa, dan bantuan dari banyak pihak. Semoga apa yang telah penulis kerjakan dapat bermanfaat bagi diri sendiri dan

orang lain. Penulis berharap, segala usaha dan doa yang tercurah dalam proses ini dapat memberikan hasil yang maksimal dan menjadi amal jariyah bagi semua pihak yang terlibat. Akhir kata, penulis memohon maaf atas segala kekurangan yang mungkin terdapat dalam penyusunan skripsi ini. Semoga Allah swt senantiasa memberkahi setiap langkah kita dan memberikan kemudahan dalam setiap usaha yang kita jalani.

*Wassalamu 'alaikum warahmatullahi wabarakatuh.*

Malang, 21 Juni 2025

Penulis

## DAFTAR ISI

HALAMAN PERSETUJUAN.....	iii
HALAMAN PENGESAHAN.....	iv
PERNYATAAN KEASLIAN TULISAN .....	v
MOTTO.....	vi
HALAMAN PERSEMBAHAN.....	vii
KATA PENGANTAR.....	viii
DAFTAR ISI .....	xii
DAFTAR GAMBAR.....	xiv
DAFTAR TABEL .....	xv
ABSTRAK.....	xvi
ABSTRACT.....	xvii
الملخص.....	xviii
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	7
1.3 Batasan Masalah .....	7
1.4 Tujuan Penelitian .....	8
1.5 Manfaat Penelitian .....	8
<b>BAB II STUDI PUSTAKA .....</b>	<b>9</b>
2.1 Penelitian Terkait .....	9
2.2 Kesehatan Mental.....	14
2.3 Klasifikasi .....	16
2.4 <i>Decision Tree</i> .....	17
2.5 <i>Random Forest</i> .....	19
<b>BAB III METODE PENELITIAN .....</b>	<b>22</b>
3.1 Desain Penelitian .....	22
3.2 Pengumpulan Data .....	23
3.3 Desain Sistem .....	26
3.4 <i>Exploratory Data Analysis (EDA)</i> .....	27
3.5 <i>Preprocessing</i> .....	28
3.6 Pemisahan Data.....	29
3.7 <i>Synthetic Minority Oversampling Technique (SMOTE)</i> .....	30
3.8 Penerapan Algoritma <i>Random Forest</i> .....	31
3.9 Skenario Pengujian .....	38
3.10 Evaluasi.....	41
3.10.1 <i>Confusion Matrix</i> .....	41
<b>BAB IV HASIL DAN PEMBAHASAN.....</b>	<b>45</b>
4.1 Hasil <i>Exploratory Data Analysis</i> .....	45
4.1.1 <i>Stacked Histogram</i> .....	45
4.1.2 <i>Clustermap</i> .....	49
4.2 Hasil <i>Preprocessing Data</i> .....	52
4.2.1 <i>Label Encoding</i> .....	52
4.2.2 Seleksi Fitur .....	54
4.3 Hasil Pemisahan Data .....	55
4.4 Hasil <i>SMOTE</i> .....	55
4.5 Hasil Uji Coba .....	57
4.5.1 Hasil Uji Coba Skenario 1 .....	57

4.6 Hasil Uji Coba Skenario 2.....	61
4.7 Pembahasan .....	64
4.8 Integrasi Islam.....	68
<b>BAB V KESIMPULAN DAN SARAN .....</b>	<b>74</b>
4.9 Kesimpulan .....	74
4.10 Saran .....	75
<b>DAFTAR PUSTAKA</b>	

## DAFTAR GAMBAR

Gambar 3. 1 Desain Penelitian Alur Proses .....	22
Gambar 3.2 Blok Diagram Desain Sistem .....	26
Gambar 3. 3 Preprocessing .....	28
Gambar 3. 4 Arsitektur Random Forest .....	31
Gambar 4. 1 Stacked Histogram .....	48
Gambar 4. 2 Clustermap .....	50
Gambar 4. 3 Confusion Matrix Skenario 1 .....	63
Gambar 4. 4 Confusion Matrix Skenario 2 .....	60
Gambar 4. 5 Classification Report 1 .....	65
Gambar 4. 6 Classification Report 2 .....	66

## DAFTAR TABEL

Tabel 3. 1 Detail Fitur Dataset .....	23
Tabel 3. 2 Daftar Pertanyaan Kuisisioner .....	24
Tabel 3. 3 <i>Sample Data</i> .....	25
Tabel 3. 4 <i>Encoding</i> .....	28
Tabel 3. 5 <i>Tuning Hyperparameter</i> .....	39
Tabel 3. 6 <i>Confusion Matrix</i> .....	42

## ABSTRAK

Kunhayati, Ummi. 2025. **Klasifikasi Kesehatan Mental pada *Imbalanced Data* Menggunakan Random Forest dan SMOTE**. Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Prof. Dr. Suhartono, M.Kom (II) Dr. M. Imamudin Lc, MA.

**Kata Kunci:** Kesehatan Mental, Random Forest, SMOTE, Klasifikasi

Kesehatan mental merupakan hal penting yang mempengaruhi kualitas hidup, terutama bagi mahasiswa yang tinggal di lingkungan pesantren yang memiliki tekanan akademik dan sosial. Penelitian ini bertujuan untuk mengklasifikasikan kesehatan mental santri Pondok Pesantren Al-Hikmah Al-Fathimiyyah Kota Malang dalam dua kategori, yaitu normal dan depresi, dengan menerapkan algoritma Random Forest serta mengatasi masalah ketidakseimbangan data menggunakan teknik *Synthetic Minority Over-sampling Technique (SMOTE)*. Data yang digunakan diperoleh melalui penyebaran kuesioner dengan 16 indikator gejala psikologis kepada 105 responden. Penelitian dilakukan dalam dua skenario: pertama, penerapan Random Forest pada data seimbang hasil SMOTE, dan kedua, penerapan Random Forest pada data asli yang tidak seimbang. Evaluasi performa model dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score. Hasil menunjukkan bahwa penerapan SMOTE meningkatkan performa model secara signifikan dalam mengenali kelas minoritas (normal), tanpa mengabaikan kemampuan klasifikasi terhadap kelas mayoritas (depresi). Model pada skenario pertama memperoleh akurasi sebesar 90,47%, nilai 90,47% juga pada skenario kedua, tetapi dengan distribusi prediksi yang lebih seimbang.

## ABSTRACT

Kunhayati, Umami. 2025. **Mental Health Classification in Imbalanced Data Using Random Forest and SMOTE**. Thesis. Department of Computer Science, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University, Malang. Supervisors: (I) Prof. Dr. Suhartono, M.Kom (II) Dr. M. Imamudin Lc, MA.

**Keywords:** Mental Health, Random Forest, SMOTE, Classification

Mental health is an important factor that affects quality of life, especially for students living in boarding school environments that have academic and social pressures. This study aims to classify the mental health of students at Pondok Pesantren Al-Hikmah Al-Fathimiyyah in Malang City into two categories: normal and depressed. This is achieved by applying the Random Forest algorithm and addressing data imbalance issues using the Synthetic Minority Over-sampling Technique (SMOTE). The data used were obtained through the distribution of a questionnaire with 16 psychological symptom indicators to 105 respondents. The study was conducted in two scenarios: first, the application of Random Forest on balanced data resulting from SMOTE, and second, the application of Random Forest on the original unbalanced data. Model performance evaluation was conducted using accuracy, precision, recall, and F1-score metrics. The results show that the application of SMOTE significantly improves the model's performance in recognizing the minority class (normal) without compromising its classification ability for the majority class (depression). The model in the first scenario achieved an accuracy of 90.47%, and the same value of 90.47% in the second scenario, but with a more balanced prediction distribution.

## الملخص

كن حياتي, أمي. ٢٠٢٥. تصنيف الصحة العقلية في البيانات غير المتوازنة باستخدام **Random Forest** و **SMOTE**. رسالة جامعية. قسم الهندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية، مالانج. المشرفون: (1) الأستاذ الدكتور سوهارتونو الماجستير. (2) الدكتور محمد امام الدين الماجستير

كلمة أساسية : الصحة العقلية، Random Forest، SMOTE، التصنيف

الصحة النفسية هي أمر مهم يؤثر على جودة الحياة، خاصة بالنسبة للطلاب الذين يعيشون في بيئة المعهد التي تتسم بالضغوط الأكاديمية والاجتماعية. تهدف هذه الدراسة إلى تصنيف الصحة العقلية لطلاب المعهد الإسلامية الحكمة الفاطمية في مالانج الى فئتين، هما: طبيعي ومكتئب، وذلك من خلال تطبيق خوارزمية Random Forest ومعالجة مشكلة عدم توازن البيانات باستخدام تقنية Synthetic Minority Over-sampling Technique (SMOTE). البيانات المستخدمة تم الحصول عليها من خلال توزيع استبيان يحتوي على ١٦ مؤشرا للأعراض النفسية على ١٠٥ مستجيبين. تم إجراء البحث في سيناريوهين: الأول، تطبيق Random Forest على البيانات المتوازنة الناتجة عن SMOTE، والثاني، تطبيق Random Forest على البيانات الأصلية غير المتوازنة. تم تقييم أداء النموذج باستخدام مقاييس الدقة، والضبط، والاسترجاع، و F1-score. أظهرت النتائج أن تطبيق SMOTE يحسن أداء النموذج بشكل ملحوظ في التعرف على الفئة الأقلية (العادية)، دون التضاي عن قدرة التصنيف على الفئة الأغلبية (الاكتئاب). حقق النموذج في السيناريو الأول دقة بنسبة ٩٠، ٤٧٪ وبلغت النسبة ٩٠، ٤٧٪ أيضا في السيناريو الثاني، ولكن مع توزيع تنبؤات أكثر توازنا.

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Kondisi kesehatan mental merupakan kondisi psikis atau kejiwaan seseorang yang tidak dapat dilihat dengan mata namun menjadi dampak bagi seseorang dalam melakukan suatu tujuan yang akan dicapai dengan kondisi sadar (Ita Wulandari & Tohir, 2019). Kehidupan seseorang tidak akan pernah terlepas dari kesejahteraan psikologis, manusia diharapkan mampu memiliki hubungan positif dengan orang lain, menerima diri, menguasai lingkungan dengan baik, memiliki hidup dengan tujuan yang jelas, dan melakukan pengembangan diri dengan kondisi kesejahteraan psikologis yang baik. Kesejahteraan psikologis yang baik diharapkan dapat membuat manusia hidup secara *wellness*, yaitu sehat secara fisik dan psikis sehingga dapat tercipta suatu kebahagiaan dalam menjalani hidup (Kurniasari et al., 2019).

Kesehatan mental menjadi pengaruh yang krusial dalam perkembangan individu. Kondisi mental yang baik akan memberikan dampak positif bagi kehidupan seseorang, karena seseorang akan lebih cepat dalam perkembangan karakter, akademik, dan fungsi otak. Sebaliknya jika kondisi mental seseorang dalam keadaan kurang baik, maka seseorang tersebut akan sulit berkembang, mudah stres, dan dapat berdampak pada perilaku kriminal (Maulana et al., 2023). Di era modern saat ini sering kita temui permasalahan pada kesehatan mental. Masalah ini menjadi tantangan kesehatan global, bahkan World Health Organization (WHO) memprediksi 1 dari 4 orang di dunia akan terkena gangguan

mental dan neurologis termasuk pada mahasiswa. Mahasiswa adalah individu yang sedang menempuh pendidikan tinggi dan merupakan generasi penerus bangsa yang harus memiliki kepercayaan diri. Kesehatan mental menentukan hasil akademik serta masa depan mahasiswa untuk meneruskan estafet bangsa demi mencapai generasi emas pada tahun 2045 (Sumathi & B., 2016).

Kesehatan mental merupakan aspek penting dalam perkembangan setiap orang, terutama bagi mahasiswa. Hasil dari zat-zat kimiawi yang tidak seimbang pada otak menyebabkan gangguan kesehatan mental (Maringka & Kusnawi, 2021). Depresi, kecemasan, dan stres merupakan contoh gangguan mental yang sering dialami mahasiswa. Kondisi tersebut dapat menjadikan mahasiswa kehilangan minat untuk beraktivitas, kehilangan nafsu makan, jam tidur yang tidak beraturan, penurunan energi dan kognitif. Hal ini dapat berdampak buruk pada proses pendidikan mahasiswa serta kualitas hidup mereka secara keseluruhan. (Mohd Shafiee & Mutalib, 2020). Banyak faktor yang mempengaruhi kesehatan mental mahasiswa, salah satunya yaitu lingkungan pendidikan. Di lingkungan tersebut, mahasiswa akan menghadapi tekanan dari berbagai sisi seperti akademik, sosial, dan personal yang dapat memicu gangguan mental seperti depresi dan bipolar (Aluh et al., 2020).

Pondok pesantren Al-Hikmah Al-Fathimiyyah adalah salah satu pesantren mahasiswa yang ada di Kota Malang. Di tempat tersebut terdapat 105 mahasiswa yang sekaligus menjadi santri dengan latar belakang dan kondisi sosial yang berbeda-beda. Dengan kondisi tersebut seluruh santri harus mampu untuk menyesuaikan diri dengan santri yang lain. Apabila psikologis santri tidak kuat

menghadapi penyesuaian tersebut, maka akan terjadi tekanan dan dapat mengakibatkan depresi. Depresi adalah penyakit kejiwaan yang diderita lebih dari 300 juta orang di dunia, 96% penyebab bunuh diri adalah depresi, tercatat 800.000 orang mati setiap harinya akibat bunuh diri. Bunuh diri merupakan faktor kedua terbesar penyebab kematian orang dengan rentang usia 15-29 tahun setelah kecelakaan lalu lintas (WHO, 2018). Remaja yang mengalami depresi akan kesulitan untuk fokus dalam kegiatan akademik maupun dalam penyesuaian diri dengan teman sebayanya (Dianovinina, 2018). Dari pengalaman penulis yang menjadi santri di Pondok Pesantren Al-Hikmah Al-Fathimiyyah dan pengambilan data awal dalam penyebaran kuesioner, terdapat beberapa santri mengalami gejala yang mengacu pada gangguan kesehatan mental berupa rasa takut, tertekan, tidak percaya diri dan kesulitan dalam menyesuaikan diri dengan kehidupan di lingkungan pesantren. Kondisi tersebut dapat mengganggu kegiatan sehari-hari yang dilakukan dan banyak dari mereka yang tidak mengetahui kondisi mentalnya dalam kondisi yang baik atau kurang baik. Mengingat pentingnya kesehatan mental bagi mahasiswa yang sekaligus menjadi santri, maka pencegahan gangguan mental diperlukan sedini mungkin. Klasifikasi kesehatan mental perlu dilakukan karena akan memberikan deteksi dini tentang kondisi yang dialami oleh santri dalam keadaan normal atau depresi sehingga bisa memilih solusi yang baik dengan kondisi masing-masing dan tidak menjadikan bunuh diri sebagai solusi dalam menyelesaikan penyakit tersebut. Dataset dari hasil kuesioner tersebut mengalami ketidakseimbangan, sehingga perlu dilakukan teknik SMOTE untuk

menyeimbangkan kelas-kelas dataset minoritas hingga mendekati kelas yang sama (Abdoh et al., 2018).

Sebagai manusia ciptaan Allah yang harus menjaga apapun yang ada dalam diri kita termasuk kesehatan psikologis. Apabila terjadi sesuatu dengan diri kita, maka kita harus memilih solusi yang tepat yang tidak membahayakan diri sendiri dan orang lain. Sebagaimana yang telah disebutkan dalam hadis riwayat Ibnu Majah nomor 2.340 yang berbunyi:

حدثنا عبد ربه بن خالد النميري أبو المغلس ، قال : حدثنا فضيل بن سليمان ، قال : حدثنا موسى بن عقبة ، قال : حدثنا إسحاق بن يحيى بن الوليد ، عن عبادة بن الصامت ، أن رسول الله صلى الله عليه وسلم قضى أن " لا ضرر ولا ضرار "

*"Telah menceritakan kepada kami Abdu Rabbih Bin Khalid An-Numairi Abu Al-Mughallis berkata, telah menceritakan kepada kami Fudhail Bin Sulaiman berkata, telah menceritakan kepada kami Musa Bin Uqbah berkata, telah menceritakan kepada Ishaq Bin Yahya Bin Al-Walid dari Ubadah Bin Ash Shamith berkata, "Rasulallah SAW memutuskan bahwa tidak boleh berbuat madharat dan hal yang menimbulkan madharat" (HR. Ibnu Majah).*

Kata *dharar* dalam hadis tersebut memiliki maksud menimbulkan kemadharatan kepada diri sendiri, sedangkan kata *dhirar* yaitu membuat kemudharatan kepada orang lain. Kata *dharar* ataupun *dhirar* sama-sama berdampak buruk bagi orang lain, baik secara langsung ataupun tidak langsung, sengaja atau tidak sengaja. Hadis tersebut menyebutkan larangan dalam melakukan perbuatan yang dapat membahayakan diri sendiri dan orang lain. Oleh karena itu, Islam menegaskan bahwa segala bentuk tindakan yang menimbulkan kerugian fisik, mental, atau sosial tidak dibenarkan, termasuk di dalamnya tindakan bunuh diri (Sabani, 2022).

Tindakan bunuh diri menjadi salah satu tindakan yang memberikan *madharat* kepada diri sendiri dan orang lain. Tindakan bunuh diri merupakan contoh nyata dari *dharar*, karena secara langsung merusak dan mengakhiri kehidupan pelakunya sendiri. Namun, dampaknya tidak berhenti pada diri sendiri saja. Bunuh diri juga dapat menjadi bentuk *dhirār* karena menimbulkan luka emosional, trauma psikologis, hingga beban sosial bagi keluarga, sahabat, dan lingkungan sekitar. Selain itu, perbuatan ini dapat menyebabkan kesedihan mendalam, rasa bersalah, bahkan stigma sosial yang berkepanjangan bagi orang-orang yang ditinggalkan.

Dengan demikian, larangan Rasulullah SAW dalam hadis tersebut mencakup tindakan bunuh diri sebagai bentuk kemudharatan yang harus dicegah. Islam sebagai agama yang menjunjung tinggi keselamatan jiwa manusia menekankan pentingnya menjaga diri dari kehancuran fisik dan mental, serta mencegah segala perbuatan yang berpotensi menyakiti orang lain, baik secara lahir maupun batin. Seorang hamba ketika sedang menderita penyakit harus bersabar dalam mencari solusi yang tepat yang sesuai dengan ajaran agama, karena setiap penyakit yang diciptakan oleh Allah itu ada obatnya.

Allah sudah berjanji untuk menciptakan obat pada segala penyakit, sebagaimana telah dijelaskan dalam Asy-Syu'ara ayat 80 yang berbunyi :

وَإِذَا مَرَضْتَ فَهُوَ يَشْفِينِ

“Apabila aku sakit, Dialah yang menyembuhkanku.” (QS. Asy Syu'ara: 80).

Dari ayat di atas dijelaskan bahwa Allah yang akan menyembuhkan manusia apabila sakit. Allah yang berkuasa untuk menyembuhkan penyakit apa saja yang

dirasakan oleh seseorang, baik penyakit fisik maupun mental. Namun demikian, manusia sebagai ciptaan-Nya juga harus berusaha dan mencari cara untuk sembuh. Ayat ini mengajarkan bahwa meskipun kita percaya akan kekuasaan Allah dalam menyembuhkan, kita tetap memiliki tanggung jawab untuk menjaga kesehatan dan berusaha mencari pengobatan yang tepat. Dengan demikian, kesadaran dan tindakan mencegah penyakit psikologis menjadi bentuk ikhtiar kita dalam menjaga amanah kesehatan yang diberikan oleh Allah SWT (Nurasih et al., 2023). Salah satu ikhtiar yang dapat dilakukan manusia adalah dengan memanfaatkan perkembangan teknologi sebagai penanganan dini untuk mencegah gangguan mental.

Perkembangan teknologi memberikan alternatif baru untuk mendeteksi dan mencegah gangguan mental. Beberapa algoritma yang sesuai dapat digunakan untuk menyelesaikan permasalahan tertentu dalam *machine learning*. Algoritma *Random Forest* adalah suatu metode *ensemble learning* dalam *machine learning* yang memanfaatkan banyak pohon keputusan (*decision tree*) untuk membuat klasifikasi yang lebih akurat dan kuat. *Random Forest* merupakan salah satu algoritma yang sangat populer dan kuat dalam *machine learning* karena dinilai mampu untuk menghasilkan klasifikasi yang akurat, mengatasi *overfitting*, dan memberikan wawasan tentang pentingnya fitur (Jindal et al., 2021). Seperti pada penelitian (Sebayang et al., 2023) yang berjudul “Klasifikasi Data Kesehatan Mental di Industri Teknologi Menggunakan Algoritma *Random Forest*”, algoritma *Random Forest* menghasilkan nilai akurasi sebesar 84%. Pada penelitian (Sun, 2024) yang berjudul “*Mental Health Classification and Diagnosis System Based on Random Forest Algorithm*”, penelitian ini menghasilkan nilai rata-rata akurasi,

presisi, *recall*, dan *f1-score* di atas angka 80% yang diperoleh dengan menggunakan algoritma *Random Forest*. Serta pada penelitian (Radhika & Thomas George, 2021) algoritma *Random Forest* menghasilkan akurasi dengan menggunakan *Scikit-Learn* sebesar 84,5%, 90,7%, dan menggunakan *Weka* sebesar 81%.

Dengan menggabungkan dataset, informasi tentang faktor-faktor pemicu gangguan kesehatan mental, dan algoritma *Random Forest* dapat membantu dalam membuat klasifikasi yang lebih akurat tentang kesehatan mental. Dengan demikian, penelitian ini bertujuan untuk mengaplikasikan algoritma *Random Forest* pada dataset yang relevan untuk mengklasifikasikan kesehatan mental, dengan harapan hasil dari penelitian ini dapat memberikan kontribusi pada upaya pencegahan risiko bunuh diri akibat kesehatan mental yang kurang baik.

## **1.2 Rumusan Masalah**

1. Bagaimana performa *Random Forest* dengan SMOTE dalam mengklasifikasi kesehatan mental santri Pondok Pesantren Al-Hikmah Al-Fathimiyyah?
2. Bagaimana performa *Random Forest* tanpa SMOTE dalam mengklasifikasi kesehatan mental santri Pondok Pesantren Al-Hikmah Al-Fathimiyyah?

## **1.3 Batasan Masalah**

1. Penelitian ini dilakukan pada santri Pondok Pesantren Al-Hikmah Al-Fathimiyyah.
2. Data yang digunakan merupakan data primer yang diperoleh dari penyebaran kuesioner terkait indikator kesehatan mental.

3. Penelitian ini dibatasi pada kondisi kesehatan mental normal (0) dan depresi (1).
4. Fokus penelitian ini adalah pada proses klasifikasi dan evaluasi model berdasarkan metrik akurasi, *precision*, *recall*, dan *f1-score*.
5. Menggunakan bahasa pemrograman Python pada *platform Google Colab*.

#### **1.4 Tujuan Penelitian**

Tujuan penelitian ini untuk mengetahui performa algoritma *Random Forest* dengan SMOTE dan tanpa SMOTE dalam mengklasifikasi kesehatan mental dalam dua kelas target, yaitu normal dan depresi berdasarkan data hasil kuesioner di Pondok Pesantren Al-Hikmah Al-Fathimiyyah.

#### **1.5 Manfaat Penelitian**

1. Penelitian ini dapat memberikan manfaat kepada pondok pesantren untuk dijadikan dasar dan gambaran awal dalam memberikan bimbingan atau tindakan preventif yang tepat terkait kesehatan mental santrinya.
2. Penelitian ini juga bermanfaat bagi santri untuk mengetahui kondisi kesehatan mental mereka sehingga dapat melakukan tindakan perbaikan atau mencari bantuan apabila diperlukan.

## BAB II

### STUDI PUSTAKA

#### 2.1 Penelitian Terkait

Dalam penelitian (Priyono et al., 2024) tentang penerapan metode *Random Forest* untuk mengklasifikasi diagnosa penyakit psikologis. Penelitian tersebut bertujuan untuk menguji performa metode *Random Forest* dengan menggunakan data pasien yang telah dipublikasi oleh Harvard University. Hasil dari penelitian tersebut memiliki nilai akurasi, *recall*, dan presisinya rata-rata di atas 90%. Nilai tersebut membuktikan bahwa metode *Random Forest* mampu dan layak digunakan untuk mengklasifikasi diagnosa penyakit psikologis.

Penelitian yang dilakukan oleh (Nurdiansyah et al., 2025) dengan judul “Mental Health Analysis to Prevent Mental Disorders in Students Using The K-Nearest Neighbor (K-NN) Algorithm and *Random Forest* Algorithm”. Penelitian ini membandingkan penggunaan algoritma *K-Nearest Neighbor* dan *Random Forest* dalam mengklasifikasi dataset “*Student mental health*” yang telah dipublikasikan pada Kaggle dengan *splitting* data 80:20 dan 70:30. Hasil penelitian tersebut menunjukkan bahwa K-NN memiliki akurasi sebesar 90% pada *splitting* data 80:20, sedangkan *Random Forest* memiliki akurasi sebesar 85% pada *splitting* data yang sama. Namun, pada *splitting* data 70:30, kinerja K-NN turun menjadi 83%, sebanding dengan akurasi *Random Forest* 83% pada *splitting* data yang sama. Penelitian ini menyimpulkan bahwa, algoritma K-NN menunjukkan akurasi yang sedikit lebih baik, sementara *Random Forest* menunjukkan kinerja yang lebih konsisten dalam berbagai pembagian data.

Penelitian yang diteliti (Wajhillah et al., 2020) tentang gangguan kejiwaan yang berjudul “Komparasi Metode Machine Learning pada Diagnosa Gangguan Kejiwaan Depresi” dengan menggunakan dataset yang bersumber dari <https://www.kaggle.com/everseek/depression>, dengan tujuan untuk mengukur performa metode Decision Tree, Naïve Bayes, KNN, dan *Random Forest*. Dalam penelitian tersebut menunjukkan bahwa algoritma *Random Forest* memiliki akurasi tertinggi dan menjadi algoritma terbaik dalam mendiagnosa gangguan kejiwaan depresi.

Penelitian dengan judul "Klasifikasi Mental Disorder dengan Menggunakan Algoritma *Random Forest*" oleh (Cahaya et al., 2024) yang bertujuan untuk mengembangkan model klasifikasi gangguan mental menggunakan algoritma *Random Forest*. Hasil penelitian menunjukkan bahwa model *Random Forest* memiliki performa terbaik dibandingkan lima model lainnya, dengan akurasi sebesar 88,89%, precision 90%, recall 89%, dan F1-score 89%. Model ini diharapkan dapat membantu mempercepat diagnosis dan meningkatkan pengambilan keputusan klinis dalam penanganan gangguan mental. Dataset yang digunakan dalam penelitian ini adalah data publik dari Kaggle, yang terdiri dari 120 data pasien dengan 17 variabel gejala seperti sadness, mood swing, sleep disorder, suicidal thoughts, anorexia, overthinking, dan lain-lain, serta label diagnosis ahli (Normal, Bipolar *Type-1*, Bipolar *Type-2*, dan Depresi).

Fitzpatrick, Fosco, dan Lippold (2024) melakukan penelitian dengan judul “*Using Random Forest to identify predictors of depression symptoms among adolescents*” untuk mengidentifikasi faktor-faktor prediktif depresi pada remaja

menggunakan algoritma *Random Forest*. Dengan menggunakan data survei dari 56.008 siswa di Kanada, penelitian ini menemukan bahwa *Random Forest* mampu menjelaskan 71% variansi skor depresi dan menghasilkan akurasi prediksi sebesar 84%. Faktor penting yang berkontribusi terhadap prediksi tersebut meliputi gejala kecemasan, koneksi sosial di sekolah, durasi tidur, dan dukungan keluarga.

Penelitian yang dilakukan oleh (Arsad et al., n.d.) berfokus pada klasifikasi gangguan mental menggunakan algoritma *Modified Balanced Random Forest* (MBRF) dan seleksi fitur berbasis korelasi (CFSSubsetEval). Studi ini bertujuan untuk meningkatkan akurasi klasifikasi dengan menangani ketidakseimbangan data dan mengevaluasi dampak seleksi fitur terhadap kinerja model. Dataset yang digunakan berasal dari Kaggle, terdiri dari 120 data dengan empat kategori diagnosis: normal, depresi, bipolar tipe-1, dan bipolar tipe-2. Proses penelitian dimulai dengan pra-pemrosesan data yang meliputi pembersihan data, transformasi, label encoding, dan normalisasi Min-Max Scaler. Selanjutnya, seleksi fitur dilakukan menggunakan CFSSubsetEval untuk mengidentifikasi fitur paling relevan. Hasil penelitian menunjukkan bahwa MBRF tanpa seleksi fitur mencapai kinerja terbaik dengan akurasi 83.33%, presisi 83.56%, recall 83.33%, dan F1-Score 83.22%. Dibandingkan dengan *Random Forest* standar, MBRF memberikan peningkatan signifikan sebesar 8.33% dalam akurasi, 8.61% dalam presisi, 8.33% dalam recall, dan 9.08% dalam F1-Score. Namun, penggunaan seleksi fitur tidak memberikan peningkatan yang signifikan, bahkan MBRF tanpa seleksi fitur menunjukkan presisi dan F1-Score yang sedikit lebih tinggi.

Penelitian yang dilakukan oleh (Pritam et al., 2024) berfokus pada analisis kesehatan mental mahasiswa menggunakan berbagai teknik klasifikasi machine learning seperti Logistic Regression, *Random Forest*, Decision Tree, dan Support Vector Machine (SVM). Studi ini menggunakan dataset dari Kaggle yang berisi variabel demografis, akademik, dan respons survei terkait kesehatan mental. Hasil penelitian menunjukkan bahwa *Random Forest* mencapai akurasi tertinggi sebesar 65% dibandingkan algoritma lainnya, dengan variabel seperti status pernikahan dan bidang studi terbukti memiliki korelasi signifikan terhadap kesehatan mental mahasiswa. Penelitian ini mengungkapkan bahwa pendekatan berbasis data dapat menjadi alat yang efektif untuk memantau kesehatan mental mahasiswa, meskipun terdapat keterbatasan dalam hal ukuran dataset dan heterogenitas data. Implikasi dari penelitian ini adalah pentingnya pengembangan model yang lebih komprehensif dengan mempertimbangkan faktor-faktor tambahan seperti data dari media sosial atau aplikasi mobile health. Penelitian ini memberikan kontribusi berharga dalam bidang analisis kesehatan mental berbasis data, sekaligus membuka peluang untuk penelitian lanjutan yang dapat mengatasi keterbatasan yang ada melalui integrasi dengan teknik-teknik mutakhir seperti deep learning atau natural language processing.

(Kumar & Kumar, 2020) melakukan penelitian terkait klasifikasi data gangguan kesehatan mental menggunakan dua alat data mining, yaitu Rattle dan Weka, dengan algoritma *Random Forest Tree*. Mereka menggunakan dataset dari Kaggle yang terdiri dari 60 observasi dengan 14 variabel input numerik dan 1 variabel target kategorikal. Hasil penelitian menunjukkan bahwa Rattle

memberikan akurasi lebih tinggi (92,85%) dibandingkan Weka (83,33%), dengan nilai precision, recall, dan F-measure yang konsisten. Variabel seperti masalah penglihatan (*vision\_problem*), jenis kelamin (*gender*), dan pendapatan pribadi (*personal\_income*) ditemukan paling berpengaruh dalam klasifikasi.

(Oktaviani et al., 2024) melakukan penelitian dengan membandingkan kinerja algoritma *Random Forest* (RF) dan *SMOTE Random Forest*. Mereka menggunakan data dari 258 mahasiswa yang diambil melalui kuesioner berisi 14 pertanyaan berdasarkan *Perceived Stress Scale* (PSS). Data tersebut kemudian melalui tahap *preprocessing* meliputi pembersihan data, transformasi ke bentuk numerik, dan pembagian dengan rasio 80:20 untuk data latih dan uji. Hasil penelitian menunjukkan bahwa metode *Random Forest* konvensional hanya mencapai akurasi 54%, precision 59%, dan recall 60%. Rendahnya kinerja ini disebabkan oleh ketidakseimbangan data, di mana kelas seperti "Sangat Berat" hanya memiliki 13 sampel. Namun, setelah diterapkan teknik SMOTE untuk menangani ketidakseimbangan kelas, performa model meningkat signifikan menjadi 71% untuk akurasi, 72% precision, dan 71% recall. SMOTE berhasil menghasilkan data sintesis sehingga distribusi kelas menjadi lebih seimbang.

Tabel 2. 1 Penelitian Terdahulu

No	Nama Peneliti	Judul Penelitian	Metode
1	Nurdiansyah dkk. (2025)	<i>Mental Health Analysis to Prevent Mental Disorders in Students Using The K-Nearest Neighbor (K-NN) Algorithm and Random Forest Algorithm</i>	K-Nearest Neighbor, <i>Random Forest</i>
2	Oktaviani dkk. (2024)	Perbandingan Kinerja <i>Random Forest</i> Dan <i>SMOTE Random Forest</i> Dalam Mendeteksi Dan Mengukur Tingkat Stres Pada Mahasiswa Tingkat Akhir	<i>Random Forest</i> , <i>SMOTE Random Forest</i>
3	Priyono dkk (2024)	Metode <i>Random Forest</i> untuk Memudahkan Klasifikasi Diagnosis Penyakit Mental	<i>Random Forest</i>

No	Nama Peneliti	Judul Penelitian	Metode
4	Cahya dkk. (2024)	Klasifikasi Mental Disorder dengan Menggunakan Algoritma <i>Random Forest</i>	<i>Random Forest</i>
5	Fitzpatrick dkk. (2024)	<i>Using Random Forest to identify predictors of depression symptoms among adolescents</i>	<i>Random Forest</i>
6	Arsad dkk (2024)	<i>Classification of Mental Disorders Using Modified Balanced Random Forest and Feature Selection</i>	<i>Random Forest, MBRF</i>
7	Pritam dkk. (2024)	<i>Classification of Student Mental Health Analysis using Logistic Regression and other classification techniques through Machine Learning Methods</i>	Logistic Regression, <i>Random Forest</i> , Decision Tree, dan Support Vector Machine
8	Wajhillah dkk. (2020)	Komparasi Metode Machine Learning pada Diagnosa Gangguan Kejiwaan Depresi	Decision Tree, Naive Bayes, KNN, <i>Random Forest</i>
9	Kumar dkk. (2020)	<i>Classification of Comparison-Based Analysis Between Rattle and Weka Tool on the Mental Health Disorder Problem Dataset Using Random Forest Tree Classifier</i>	<i>Random Forest</i>

Tabel 2.1 menyajikan ringkasan penelitian terdahulu yang menggunakan berbagai metode dalam klasifikasi penyakit. Tabel ini mencakup judul penelitian, peneliti, metode yang digunakan, dan hasil penelitian masing-masing. Dalam Tabel ini, ditampilkan beberapa penelitian yang mengaplikasikan algoritma *Random Forest* dalam mendeteksi dan mengklasifikasikan kesehatan mental. Informasi yang terdapat dalam tabel ini memberikan gambaran mengenai efektivitas metode yang digunakan dalam konteks kesehatan, serta hasil akurasi yang dicapai oleh masing-masing penelitian

## 2.2 Kesehatan Mental

Secara umum kesehatan mental merupakan keadaan, situasi yang bersifat kejiwaan. Kesehatan mental juga diuraikan sebagai suatu keadaan yang ada dalam diri seorang individu yang dapat mempengaruhi sikap dan perilaku individu tersebut. Kesehatan mental dapat diartikan sebagai suatu keadaan psikis yang tidak

tampak oleh mata dan mendasari seseorang untuk berperilaku secara sadar (Stevani et al., 2019).

Seseorang memiliki kesehatan mental yang berbeda-beda sesuai dengan kondisi emosionalnya. Seseorang yang masih bisa mengendalikan emosinya dengan baik, itu menandakan bahwa orang tersebut termasuk dalam kategori normal. Namun seseorang juga bisa pada kondisi depresi. Depresi adalah gangguan mental yang umumnya ditandai dengan perasaan depresi, kehilangan minat atau kesenangan, penurunan energi, perasaan bersalah atau rendah diri, sulit tidur atau nafsu makan berkurang, perasaan kelelahan dan kurang konsentrasi. Kondisi tersebut dapat menjadi kronis dan berulang, dan secara substansial dapat mengganggu kemampuan individu dalam menjalankan tanggung jawab sehari-hari. Berdasarkan *Diagnostic and Statistical Manual of Mental Disorder, Fifth Edition (DSM-V)*, seseorang dikatakan depresi jika setidaknya selama dua minggu mengalami minimal lima dari sembilan kriteria berikut, yaitu (1) adanya perasaan depresi yang muncul di sebagian besar waktu, bahkan hampir setiap hari, (2) adanya penurunan minat dan kesenangan di hampir sebagian besar kegiatan dan hampir setiap hari, (3) adanya perubahan berat badan atau nafsu makan yang signifikan, (4) adanya perubahan tidur: menjadi insomnia atau hipersomnia, (5) adanya perubahan aktivitas, (6) merasa kelelahan dan kehilangan energi, (7) munculnya perasaan bersalah atau tidak berharga yang berlebihan dan sebenarnya tidak pantas muncul, (8) mengalami penurunan konsentrasi, dan (9) memiliki pikiran berulang tentang kematian (tidak hanya takut mati), adanya keinginan bunuh diri berulang tanpa

rencana spesifik, usaha bunuh diri, atau rencana spesifik untuk melakukan bunuh diri (Santrock, 2019).

Gangguan depresi manik adalah salah satu gangguan psikologis yang fokusnya pada suasana perasaan/*mood*. Perasaan normal yang dirasakan oleh manusia dapat berubah dari gembira menjadi sedih. Gangguan bipolar episode pertama sering terjadi pada remaja yang diawali dengan fase tanpa gejala, selanjutnya akan ada episode pergantian antara mood meninggi dan menurun dalam fase kambuh (Maramis M Margarita, 2022). Kondisi mood meninggi atau episode manik adalah kondisi seseorang merasa sangat bersemangat dan berenergi, sedangkan mood menurun atau hipomanik adalah kondisi seseorang merasa putus asa. Apabila seseorang berada pada titik terendah melebihi hipomanik, maka orang tersebut termasuk dalam episode depresi. Gangguan bipolar dibagi menjadi tiga kondisi berdasarkan lamanya pasien dalam menjalani episode emosional. Kondisi pertama yaitu Bipolar I, kondisi ini ditandai dengan episode manik yang parah dan dapat mengakibatkan rawat inap pada pasien. Selanjutnya, Bipolar II ditandai dengan seseorang yang berada pada episode depresi dan hipomanik. Kondisi yang terakhir yaitu siklotimik yang ditandai dengan berlangsungnya episode depresi dengan jangka waktu yang lama dan manik (Steen, 2021).

### **2.3 Klasifikasi**

Klasifikasi adalah proses mengkategorikan objek atau data ke dalam kategori atau kelas tertentu berdasarkan atribut atau karakteristiknya (Mourya et al., 2018). Menurut etimologinya, “klasifikasi” berasal dari bahasa Inggris *classification* dan bahasa Prancis *classification* yang mengacu pada metode pengelompokan data

secara sistematis atau menurut beberapa aturan yang telah diterapkan sebelumnya. Berdasarkan Kamus Besar Bahasa Indonesia, klasifikasi adalah pengaturan kelompok atau kelas secara sistematis menurut aturan atau standar yang telah ditetapkan.

Metode klasifikasi digunakan untuk membagi item atau data ke dalam kelas atau kategori berbeda berdasarkan karakteristiknya. Dengan mengelompokkan objek yang serupa, tujuan utama klasifikasi adalah untuk mengatur dan memahami data dalam jumlah besar. Klasifikasi banyak digunakan di berbagai bidang termasuk *machine learning*, penggalian data, pencarian informasi, dan pengenalan gambar (Mourya et al., 2018).

Klasifikasi diperlukan dalam berbagai bidang dan aplikasi untuk mengatur dan mengkategorikan data atau dokumen dalam jumlah besar berdasarkan karakteristik atau atributnya. Klasifikasi memungkinkan pemrosesan dan analisis data yang efisien dengan mengelompokkan data yang serupa, sehingga dapat membantu dalam membuat keputusan yang tepat (Bhavani & Santhosh Kumar, 2021).

Dalam penelitian ini, algoritma klasifikasi digunakan untuk mengklasifikasikan kelas pasien yang kemungkinan memiliki kesejahteraan psikologis yang kurang baik berdasarkan berbagai atribut datanya dengan kelas 0 (normal) dan kelas 1 (depresi) (Jindal et al., 2021).

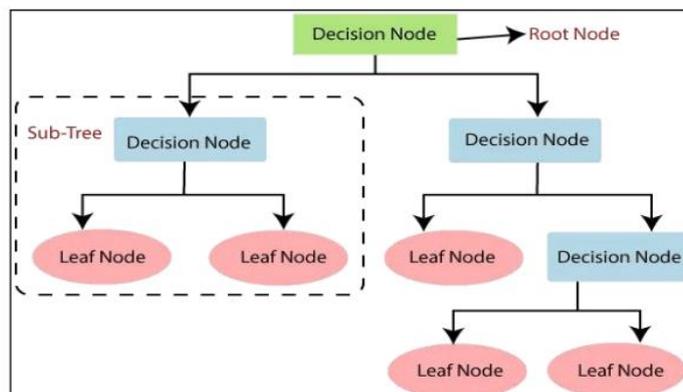
#### **2.4 Decision Tree**

Decision Tree merupakan suatu model prediktif yang memiliki struktur menyerupai pohon, di mana setiap node merepresentasikan suatu keputusan, dan

setiap cabang menunjukkan kemungkinan konsekuensi dari keputusan tersebut. Model ini tergolong ke dalam metode pembelajaran terawasi (*supervised learning*), yang berarti membutuhkan data latih (*training dataset*) untuk menggantikan peran pengalaman manusia sebelumnya dalam proses pengambilan keputusan (Ramadhon et al., 2024). Struktur pada pohon keputusan terdiri atas simpul akar (*root node*), simpul internal (*internal node*), dan simpul daun (*leaf node*). Secara visual, pohon keputusan menyerupai diagram alir (*flowchart*), di mana setiap simpul internal merepresentasikan kondisi atau kriteria pengujian, sedangkan simpul daun merepresentasikan hasil klasifikasi atau kelas dari suatu data. Penyusunan pohon keputusan dilakukan dengan pendekatan *divide and conquer*, yaitu membagi permasalahan menjadi sub-permasalahan yang lebih kecil secara berulang. Setiap jalur dari akar hingga daun dalam pohon tersebut menggambarkan suatu aturan klasifikasi yang digunakan untuk menentukan kelas suatu data (Kusumarini et al., 2021).

Pembuatan model *Decision Tree* dilakukan dengan cara membagi data ke dalam kelompok-kelompok yang lebih kecil berdasarkan atribut yang dimiliki oleh data tersebut. Proses pemisahan ini dilakukan secara berulang hingga seluruh data yang berasal dari kelas yang sama terkelompok dalam satu bagian yang seragam. Dalam struktur pohon keputusan, terdapat beberapa istilah penting, antara lain *decision node*, yaitu simpul yang merepresentasikan fitur atau atribut yang digunakan untuk mengambil keputusan. Simpul keputusan yang berada di posisi paling atas disebut sebagai *root node*. Selain itu, terdapat *leaf node* yang menunjukkan hasil akhir atau kelas dari suatu keputusan, serta *subtree* yang

merupakan bagian atau cabang dari keseluruhan pohon keputusan (Ramadhon et al., 2024).



Gambar 2.1 Konsep *Decision Tree*

Sumber: <https://wadhwatanya1234.medium.com/decision-tree-model-1089c11ab22>

## 2.5 *Random Forest*

*Random Forest* adalah salah satu metode *ensemble learning* yang prosesnya menggabungkan beberapa pohon keputusan (*decision tree*) untuk meningkatkan hasil akurasi prediksi dan mengurangi *overfitting*. Setiap pohon keputusan dalam *Random Forest* dibangun dari sampel acak data pelatihan dan subset acak dari fitur. Keunggulan utama *Random Forest* adalah kemampuannya menangani data dengan jumlah fitur yang besar dan sifatnya yang *robust* terhadap data yang hilang atau nilai pencilan (Marsuhandi et al., 2020).

*Random Forest* bekerja dengan membuat beberapa pohon keputusan dari sampel data yang berbeda (*bootstrap sampling*) dan menggunakan rata-rata prediksi dari semua pohon untuk menentukan hasil akhir. Proses ini membantu mengurangi variabilitas dan meningkatkan stabilitas model. Setiap pohon dalam hutan

menghasilkan satu prediksi, dan hasil akhir ditentukan oleh mayoritas suara dari semua pohon (Suci Amaliah et al., 2022).

Dalam Al-Qur'an, pohon (syajarah) digunakan dalam berbagai konteks simbolik, yaitu sebagai gambaran tentang kehidupan, keputusan, dan kebaikan atau keburukan. Misalnya dalam Surat Ibrahim ayat 24-25:

أَلَمْ تَرَ كَيْفَ ضَرَبَ اللَّهُ مَثَلًا كَلِمَةً طَيِّبَةً كَشَجَرَةٍ طَيِّبَةٍ أَصْلُهَا ثَابِتٌ وَفَرْعُهَا فِي السَّمَاءِ  
تُؤْتِي أُكْلَهَا كُلَّ حِينٍ بِإِذْنِ رَبِّهَا وَيَضْرِبُ اللَّهُ الْأَمْثَالَ لِلنَّاسِ لَعَلَّهُمْ يَتَذَكَّرُونَ

"*Tidakkah kamu perhatikan bagaimana Allah telah membuat perumpamaan kalimat yang baik seperti pohon yang baik, akarnya teguh dan cabangnya (menjulang) ke langit, pohon itu memberikan buahnya pada setiap waktu dengan izin Tuhannya*" (QS. Ibrahim: 24-25)

Ayat ini menggambarkan bahwa pohon yang baik (*syajarah tayyibah*) dengan akar kuat dan cabang yang menjulang melambangkan kebaikan, kemantapan, dan kebermanfaatannya yang terus menerus (Sauda, 2020). Ini bisa diparalelkan dengan prinsip decision tree yang kuat, yang memiliki akar keputusan (fitur penting), cabang (*split* data), dan hasil (prediksi/*classification*).

Algoritma *Random Forest Classifier* dimulai dengan memuat data pelatihan ke dalam memori. Setelah itu, data tersebut dibagi menjadi beberapa subset acak menggunakan teknik bootstrap. Teknik ini memungkinkan pengambilan sampel dengan penggantian dari data pelatihan asli, sehingga setiap subset dapat mengandung data yang berulang (Marsuhandi et al., 2020). Untuk setiap subset data yang dihasilkan, sebuah pohon keputusan dibuat. Pohon keputusan ini dibangun dengan membatasi kedalaman pohon atau jumlah maksimum fitur yang dapat digunakan untuk setiap split guna menghindari *overfitting*. Pada setiap node dalam

pohon, subset fitur acak dipilih untuk mencari split terbaik, menambah variasi dan mengurangi korelasi antar pohon. Proses ini diulang sebanyak  $n\_estimator$  kali, yang merupakan jumlah pohon yang diinginkan dalam model ensemble (Tamba & -, 2022).

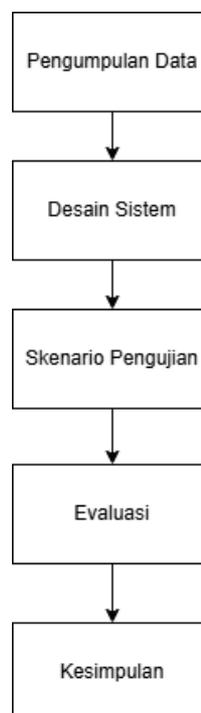
Setelah semua pohon keputusan dibuat, model siap untuk menentukan prediksi terhadap sampel baru. Prediksi ini dilakukan dengan mengumpulkan hasil dari setiap pohon keputusan. Untuk setiap pohon, data baru diklasifikasikan dan hasil prediksinya dicatat. Setelah semua hasil prediksi dari setiap pohon terkumpul, dilakukan agregasi prediksi dengan menghitung jumlah prediksi untuk setiap kelas dari semua pohon keputusan. Terakhir, data baru diklasifikasikan ke dalam kelas dengan jumlah prediksi terbanyak (Marsuhandi et al., 2020). Artinya, kelas yang paling sering diprediksi oleh pohon-pohon keputusan akan menjadi kelas akhir untuk data baru, mengikuti prinsip mayoritas suara dalam *ensemble learning*.

## BAB III

### METODE PENELITIAN

#### 3.1 Desain Penelitian

Pada subbab ini menjelaskan tahapan-tahapan yang dilakukan dalam proses penelitian. Desain penelitian dibuat sebagai panduan untuk mencapai tujuan penelitian supaya lebih efisien dan terarah. Adapun alur penelitian ini disusun dalam beberapa tahapan utama, yaitu: pengumpulan data, desain sistem, skenario pengujian, evaluasi, dan kesimpulan. Setiap tahapan memiliki peran penting dalam mendukung keberhasilan penelitian, mulai dari tahap awal pengumpulan informasi hingga tahap akhir penarikan kesimpulan. Desain ini diharapkan mampu menggambarkan secara jelas dan terstruktur alur kerja penelitian yang dilaksanakan.



Gambar 3. 1 Desain Penelitian Alur Proses

### 3.2 Pengumpulan Data

Pada tahap ini dilakukan pengumpulan data melalui penyebaran kuesioner kepada seluruh santri di Pondok Pesantren Al-Hikmah Al-Fathimiyyah Malang pada tanggal 30 April – 7 Mei 2025 melalui Google Formulir. Kuesioner tersebut dibagikan kepada seluruh santri yang berjumlah 105 data dengan 18 atribut seperti pada tabel penjelasan di bawah.

Tabel 3. 1 Detail Fitur Dataset

No	Fitur	Tipe Data	Keterangan
1	<i>Name/Initial</i>	String	Nama atau inisial responden
2	<i>Sadness</i>	String	Perasaan sedih yang berkepanjangan
3	<i>Euphoric</i>	String	Perasaan bahagia yang berlebihan
4	<i>Exhausted</i>	String	Kelelahan psikologis dan fisik yang parah
5	<i>Sleep Disorder</i>	String	Gangguan tidur
6	<i>Mood Swing</i>	String	Perubahan suasana hati yang cepat
7	<i>Suicidal thoughts</i>	String	Keinginan untuk mengakhiri hidup
8	<i>Anorxia</i>	String	Kehilangan nafsu makan karena takut terjadinya kenaikan berat badan
9	<i>Authority Respect</i>	String	Sikap penghormatan terhadap seseorang
10	<i>Try-Explanation</i>	String	Kebiasaan untuk terus melakukan pembenaran diri
11	<i>Aggressive Response</i>	String	Emosi yang tidak dapat dikendalikan
12	<i>Ignore &amp; Move-On</i>	String	Kebiasaan mengabaikan masalah tanpa penyelesaian
13	<i>Nervous Break-down</i>	String	Keadaan emosional yang gugup dan tidak stabil
14	<i>Admit Mistakes</i>	String	Kemampuan dan ketidakmampuan mengakui kesalahan
15	<i>Overthinking</i>	String	Kebiasaan memikirkan sesuatu secara berlebihan
16	<i>Concentration</i>	String	Kemampuan untuk fokus
17	<i>Optimism</i>	String	Memiliki harapan yang baik untuk masa depan
18	<i>Expert Diagnose</i>	String	Diagnosa kesehatan mental dalam dua kelas yang disimbolkan dengan nilai 0 (normal) dan 1 (depresi)

Pada tabel 3. 1 terdapat 18 atribut dalam dataset, namun dalam pertanyaan kuesioner hanya menggunakan 17 atribut karena atribut *expert diagnose* adalah atribut yang digunakan untuk menuliskan diagnosa kesehatan mental responden dan sebagai diagnosa aktual untuk diklasifikasi menggunakan *Random Forest*.

Tabel 3. 2 Daftar Pertanyaan Kuisisioner

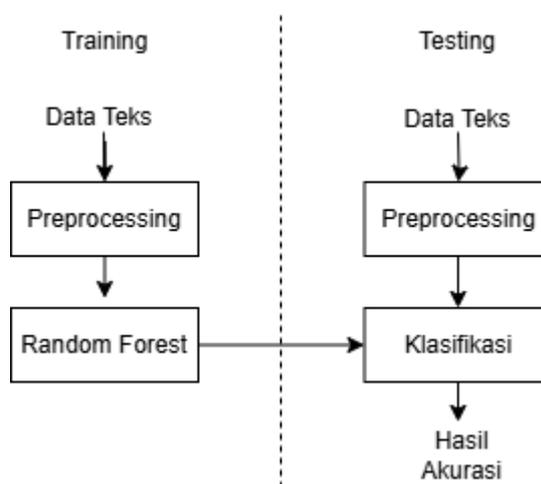
No	Fitur	Pertanyaan	Pilihan Jawaban
1	<i>Sadness</i>	Saya merasa sedih tanpa alasan	Sangat sering, sering, kadang-kadang, tidak pernah
2	<i>Euphoric</i>	Saya merasa bahagia tanpa alasan	Sangat sering, sering, kadang-kadang, tidak pernah
3	<i>Exhausted</i>	Saya merasa sangat lelah meskipun tidak melakukan aktivitas fisik berat	Sangat sering, sering, kadang-kadang, tidak pernah
4	<i>Sleep Disorder</i>	Saya mengalami kesulitan tidur di malam hari	Sangat sering, sering, kadang-kadang, tidak pernah
5	<i>Mood Swing</i>	Apakah Anda pernah mengalami perubahan suasana hati secara tiba-tiba tanpa alasan?	Ya, tidak
6	<i>Suicidal thoughts</i>	Apakah Anda pernah berfikir untuk mengakhiri hidup?	Ya, tidak
7	<i>Anorxia</i>	Apakah Anda merasa tidak puas dengan bentuk tubuh Anda?	Ya, tidak
8	<i>Authority Respect</i>	Apakah Anda merasa kesulitan dalam menjalankan perintah dan aturan dari orang lain?	Ya, tidak
9	<i>Try Explanation</i>	Apakah Anda akan memberi penjelasan kepada orang lain saat Anda tidak dapat menyelesaikan tugas yang menjadi tanggung jawab Anda?	Ya, tidak
10	<i>Aggressive Respons</i>	Apakah Anda mudah marah ketika sesuatu tidak berjalan sesuai rencana?	Ya, tidak
11	<i>Ignore &amp; Move-On</i>	Apakah Anda pernah berpura-pura dalam kondisi baik-baik saja dan mengabaikan masalah yang sedang terjadi?	Ya, tidak
12	<i>Nervous Break-down</i>	Apakah Anda pernah merasa tertekan hingga mengganggu kegiatan Anda sehari-hari?	Ya, tidak
13	<i>Admit Misktakes</i>	Apakah Anda pernah merasa takut untuk mengakui kesalahan?	Ya, tidak
14	<i>Overthinking</i>	Apakah Anda pernah merasa cemas dan memikirkan berulang-ulang akan kejadian yang sudah ataupun belum terjadi?	Ya, tidak
15	<i>Concentracion</i>	Seberapa besar Tingkat focus Anda pada tugas yang sedang dikerjakan?	1-10
16	<i>Optimsism</i>	Seberapa besar keyakinan Anda bahwa segala sesuatu akan berjalan dengan baik?	1-10

Tabel 3. 3 Sample Data

Name/Initial	Sadness	Euphoric	Exhausted	Sleep Disorder	Mood Swing	Suicidal thoughts	Anorexia	Authority Respect	Try Explanati	Aggressive & Respons	Ignore & Move-on	Nervous Break-	Admit Mistakes	Overthin	Concentr	Optimism
Miskay cumill	Kadang-kadang	Kadang-kadang	Sering	Sering	Ya	Tidak	Ya	Ya	Ya	Ya	Ya	Ya	Ya	Ya	8	9
sasa	Kadang-kadang	Sering	Sangat Sering	Sering	Ya	Tidak	Tidak	Ya	Ya	Ya	Ya	Ya	Ya	Ya	8	8
Aisyah	Sangat Sering	Sangat Sering	Sering	Sering	Ya	Ya	Ya	Ya	Ya	Ya	Ya	Ya	Ya	Ya	5	6
Fatimatuz Z	Sangat Sering	Sangat Sering	Sering	Sangat Sering	Ya	Ya	Ya	Ya	Ya	Ya	Ya	Ya	Ya	Ya	10	10
Zahro'	Kadang-kadang	Kadang-kadang	Kadang-kadang	Tidak Pernah	Ya	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Tidak	Ya	5	6
Dinda	Sering	Sering	Sangat Sering	Sangat Sering	Ya	Ya	Ya	Ya	Ya	Tidak	Ya	Tidak	Tidak	Ya	5	7
Anid	Kadang-kadang	Sering	Kadang-kadang	Kadang-kadang	Ya	Tidak	Tidak	Tidak	Ya	Ya	Ya	Ya	Tidak	Ya	6	8
Faridah	Sering	Tidak Pernah	Sering	Sering	Ya	Tidak	Tidak	Tidak	Ya	Ya	Ya	Ya	Ya	Ya	6	8
indi cantiqq	Kadang-kadang	Kadang-kadang	Tidak Pernah	Tidak Pernah	Ya	Tidak	Tidak	Tidak	Tidak	Tidak	Ya	Ya	Tidak	Ya	8	10
Anika	Kadang-kadang	Kadang-kadang	Kadang-kadang	Kadang-kadang	Ya	Tidak	Tidak	Tidak	Ya	Tidak	Ya	Ya	Ya	Ya	7	9
nuha	Kadang-kadang	Kadang-kadang	Kadang-kadang	Sering	Tidak	Tidak	Tidak	Tidak	Ya	Tidak	Tidak	Tidak	Tidak	Ya	8	9

### 3.3 Desain Sistem

Desain penelitian ini menjelaskan alur proses klasifikasi teks menggunakan algoritma *Random Forest*, yang dibagi menjadi dua tahap utama: *Training* dan *Testing*. Setiap tahap memiliki fungsi dan proses yang spesifik untuk memastikan model yang dihasilkan mampu mengklasifikasikan data secara akurat dan terukur.



Gambar 3.2 Blok Diagram Desain Sistem

Pada Gambar 3. 2 dibagi menjadi dua bagian utama yaitu, *Training* (pelatihan) dan *Testing* (pengujian). Pada bagian *training*, dimulai dari data teks mentah yang kemudian diproses melalui tahap *preprocessing* dengan tujuan untuk membersihkan dan mempersiapkan data agar sesuai dengan format yang dibutuhkan oleh algoritma *Random Forest*. Selanjutnya proses *training* dilakukan untuk membentuk model klasifikasi. Model ini yang nantinya digunakan untuk mengklasifikasikan data baru pada tahap pengujian. Tahap *testing* dilakukan menggunakan data teks yang belum pernah digunakan sebelumnya. Data ini juga harus melalui *preprocessing* agar memiliki struktur yang sama dengan data *training*. Model yang telah dilatih akan digunakan untuk memprediksi kelas dari

data uji tersebut. Selanjutnya, hasil prediksi dibandingkan dengan label sebenarnya menggunakan metode evaluasi *Confusion Matrix* untuk menghitung metrik performa. Hasil dari *confusion matrix* kemudian dianalisis untuk mengetahui sejauh mana model mampu mengklasifikasikan data dengan benar. Nilai akurasi menjadi indikator utama dalam menilai kinerja model.

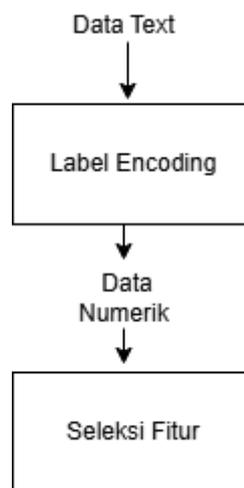
### **3.4 Exploratory Data Analysis (EDA)**

Dalam tahap eksplorasi data, terdapat dua jenis visualisasi yang digunakan untuk memahami pola dan hubungan antar variabel gejala dengan diagnosis. Setiap gejala divisualisasikan dalam bentuk histogram bertumpuk yang menggambarkan jumlah responden pada masing-masing tingkat keparahan gejala, dibedakan berdasarkan kategori diagnosis yang ditunjukkan dengan warna berbeda. Kategori 0 (Normal) ditampilkan dengan warna ungu tua, kategori 1 (Depresi) dengan warna biru kehijauan. Pola distribusi ini juga dilengkapi dengan garis KDE (*Kernel Density Estimate*) yang memperlihatkan kecenderungan nilai secara halus. Terlihat bahwa beberapa gejala seperti *Suicidal Thoughts*, *Exhausted*, dan *Nervous Breakdown* memiliki distribusi nilai yang berbeda cukup jelas antara kategori diagnosis, yang mengindikasikan bahwa gejala-gejala tersebut dapat menjadi indikator kuat dalam membedakan kesehatan mental responden.

Selain itu juga terdapat *clustermap* yang mengikuti skema warna *magma*, di mana warna ungu gelap menunjukkan korelasi rendah atau negatif, sedangkan warna kuning terang menandakan korelasi yang tinggi. Di samping *heatmap* ditampilkan dendrogram yang menunjukkan pengelompokan gejala berdasarkan kemiripan korelasi.

### 3.5 Preprocessing

Tahap *preprocessing* digunakan untuk mengolah data yang berasal dari sumber mentah yang belum terstruktur dengan baik. Proses transformasi dan pembersihan dilakukan agar data menjadi siap untuk dianalisis atau digunakan dalam pelatihan model *machine learning*.. Berikut proses yang terjadi dalam tahapan *preprocessing*:



Gambar 3. 3 *Preprocessing*

#### a. Label *Encoding*

Pada penelitian ini, dataset yang digunakan berupa teks atau kategorikal yang berisi *String*, supaya dapat diproses oleh *machine learning*, data tersebut harus diubah ke dalam bentuk numerik. Berikut perbedaan data sebelum dan sesudah dilakukan *encoding*:

Tabel 3. 4 *Encoding*

Sebelum Encoding	Setelah Encoding
Sangat Sering	3
Sering	2
Kadang-kadang	1
Tidak Pernah	0

Sebelum Encoding	Setelah Encoding
Ya	1
Tidak	0
Normal	0
Depresi	1
1 from 10	1

Setelah dilakukan tahap label encoding, maka data yang awalnya berupa teks, maka akan berubah menjadi data numerik yang hanya berisi angka seperti pada Tabel 3. 4.

#### b. Seleksi Fitur

Pada tahapan ini dilakukan pemisahan antara fitur (atribut independen) dan target (atribut dependen) yang akan digunakan dalam proses klasifikasi. Dataset awal terdiri dari 18 atribut, termasuk kolom *Name/Initial* yang hanya berisi informasi identitas responden dan tidak berkontribusi terhadap proses analisis, sehingga dihapus. Selanjutnya, kolom *Expert Diagnose* ditentukan sebagai label atau target klasifikasi. Dengan menghapus kedua kolom tersebut (*Name/Initial* dan *Expert Diagnose*) dari dataset, diperoleh 16 atribut yang digunakan sebagai fitur ( $x$ ). Target klasifikasi disimpan dalam variabel  $y$ , yang berisi nilai dari kolom *Expert Diagnose*.

### 3.6 Pemisahan Data

Tahapan pemisahan data akan memisah data menjadi data latih dan data uji yang dilakukan sebelum menerapkan ke model *machine learning*. Tahap ini

membagi dataset menjadi 80% data latih dan 20% data uji dengan stratifikasi berdasarkan label, sehingga proporsi kelas di kedua subset tetap terjaga. Data tersebut digunakan untuk pelatihan dan evaluasi model klasifikasi.

### 3.7 Synthetic Minority Oversampling Technique (SMOTE)

Teknik *Synthetic Minority Oversampling Technique* (SMOTE) digunakan untuk mengatasi *imbalanced* data yang dapat mempengaruhi kinerja model klasifikasi. Dalam penelitian ini, dataset memiliki ketidakseimbangan signifikan, dengan sampel 22 pada kelas 0 (normal), 83 sampel pada kelas 1 (depresi). SMOTE menghasilkan sampel sintesis baru untuk kelas minoritas (kelas 0), yang membantu mengurangi perbedaan jumlah antara kedua kelas, sehingga meningkatkan akurasi model dalam mengklasifikasikan kedua kelas tersebut. Berikut langkah-langkah dalam menerapkan teknik SMOTE (Mohammed, 2020):

- a. Memilih secara acak satu sampel dari data minoritas.
- b. Mengidentifikasi tetangga terdekat ( $k$ ) dari sampel minoritas yang terpilih.
- c. Membuat sampel data sintesis baru dengan menggabungkan sampel minoritas terpilih dengan tetangga terdekatnya menggunakan kombinasi berbobot, sesuai dengan persamaan yang relevan, dengan menggunakan persamaan berikut:

$$x_{new} = x_i + \alpha (x_j - x_i) \quad (3.1)$$

Keterangan :

$x_{new}$  : Instance sintesis baru yang dihasilkan.

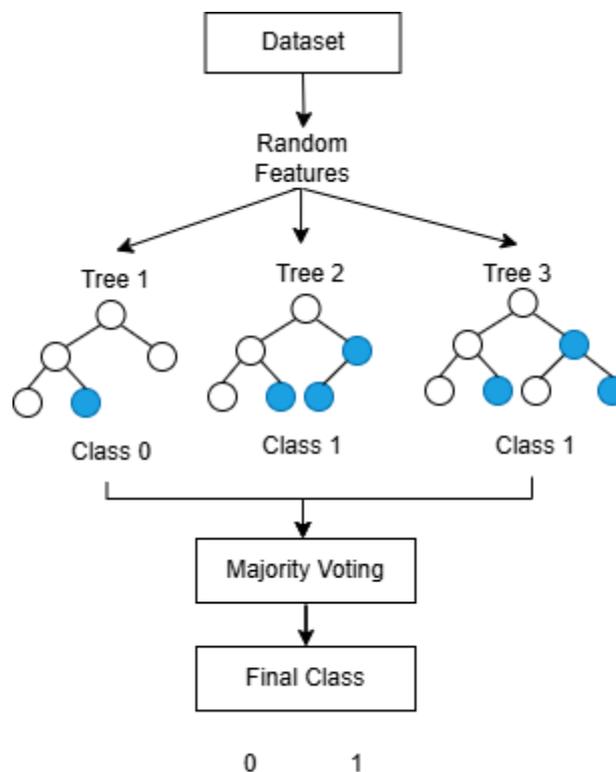
$x_i$  : sampel kelas minoritas yang dipilih.

$x_j$  : Salah satu tetangga terdekat dari  $x_i$ , yang juga merupakan sampel dari kelas minoritas.

$\alpha$  : bilangan acak rentang 0 dan 1.

### 3.8 Penerapan Algoritma *Random Forest*

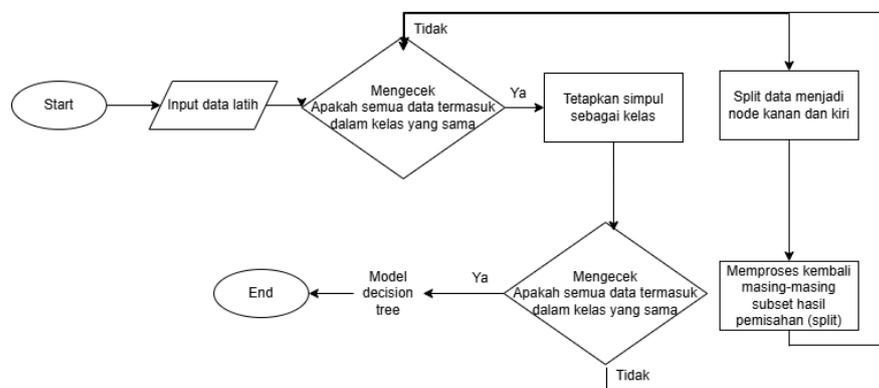
Algoritma *Random Forest* bekerja dengan membangun sejumlah pohon keputusan secara acak dan menggabungkan prediksi dari masing-masing pohon untuk menghasilkan keputusan akhir yang lebih akurat dan stabil. Pemahaman terhadap arsitektur dan proses kerja *Random Forest* menjadi penting untuk menjelaskan bagaimana data mentah diolah hingga menghasilkan klasifikasi kesehatan mental responden.



Gambar 3. 4 Arsitektur *Random Forest*

Proses kerja algoritma ini diawali dengan pengambilan sampel data secara acak dari dataset utama menggunakan teknik *bootstrap sampling*. Setiap pohon dibangun dengan data yang berbeda menggunakan teknik *bootstrap sampling*, namun seluruh fitur dipertimbangkan pada setiap pemisahan (*split*).

Setiap pohon keputusan (*decision tree*) dibangun berdasarkan subset data hasil teknik bootstrap sampling. Di setiap *node*, algoritma *Random Forest* secara acak memilih sejumlah subset fitur dari total fitur yang tersedia. Dalam penelitian ini, terdapat 16 fitur, sehingga pemilihan acak menggunakan rumus  $\sqrt{m}$  menghasilkan 4 fitur per *node*. Pemilihan acak subset fitur ini bertujuan untuk mengurangi korelasi antar pohon, sehingga meningkatkan keanekaragaman (*diversity*) dan mengurangi *overfitting*.

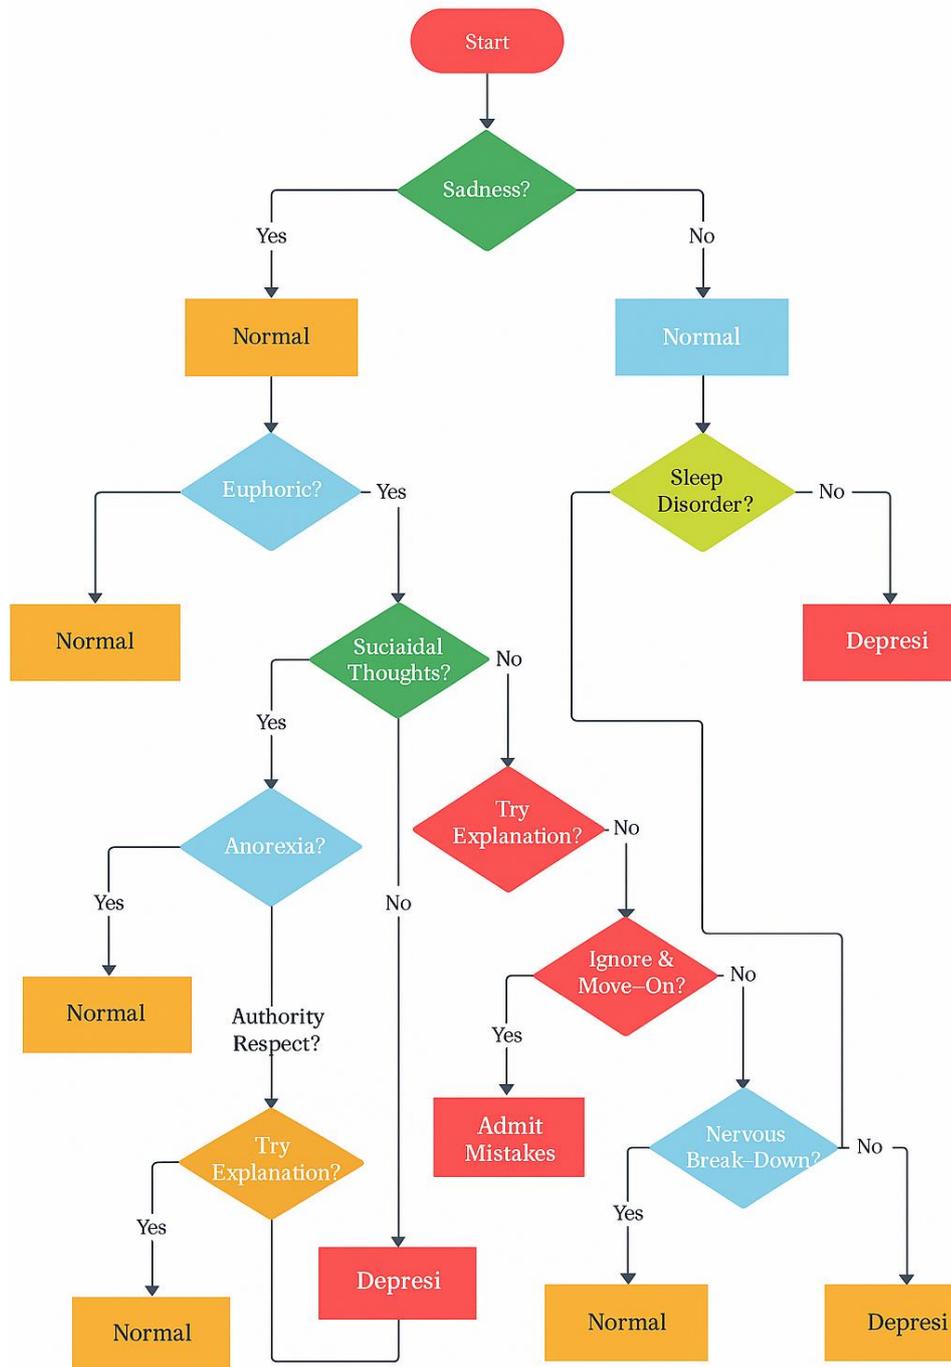


Gambar 3. 5 Flowchart Decision Tree

Flowchart pada Gambar 3.5 menggambarkan alur proses pembentukan model *decision tree* yang digunakan dalam penelitian ini. Proses dimulai dengan melakukan *input* data latih yang telah melalui tahap praproses sebelumnya. Selanjutnya, sistem akan memeriksa apakah seluruh data yang terdapat dalam simpul (*node*) tersebut termasuk dalam kelas yang sama. Jika semua data berada dalam satu kelas yang sama, maka simpul tersebut akan ditetapkan sebagai simpul daun (*leaf node*), dan proses pada cabang tersebut dihentikan. Namun, apabila data terdiri dari lebih dari satu kelas, maka dilakukan proses pemisahan (*split*) terhadap

data berdasarkan atribut terbaik. Proses ini menghasilkan dua subset data, yaitu subset untuk *node* kiri dan *node* kanan.

Masing-masing subset hasil pemisahan kemudian diproses kembali dengan langkah yang sama secara rekursif. Proses ini terus berulang hingga setiap simpul hanya mengandung data dari satu kelas atau hingga kondisi terminasi tertentu terpenuhi. Hasil akhir dari proses ini adalah model pohon keputusan yang dapat digunakan untuk melakukan klasifikasi terhadap data baru. Flowchart tersebut menggambarkan secara umum prinsip kerja algoritma *decision tree* yang bersifat rekursif dan berbasis pada pemilihan atribut terbaik untuk membagi data agar mencapai klasifikasi yang optimal.



Gambar 3. 6 Pohon Keputusan

Pada Gambar 3. 6 menggambarkan proses klasifikasi status kesehatan mental individu ke dalam dua kelas, yaitu Normal dan Depresi, berdasarkan

beberapa indikator psikologis dan perilaku. Proses klasifikasi ini dimulai dengan mengidentifikasi apakah seseorang mengalami perasaan sedih (*sadness*) secara signifikan. Jika individu tidak menunjukkan tanda-tanda kesedihan, maka dilanjutkan dengan pemeriksaan apakah individu mengalami gangguan tidur (*sleep disorder*). Apabila tidak terdapat gangguan tidur, maka individu diklasifikasikan sebagai Depresi, karena kurangnya gejala utama lainnya dapat menutupi depresi atipikal. Sebaliknya, jika terdapat gangguan tidur, maka pemeriksaan dilanjutkan pada indikator lainnya seperti kecenderungan mengabaikan masalah (*ignore and move on*), ledakan emosional (*nervous breakdown*), hingga kemampuan untuk mengakui kesalahan (*admit mistakes*).

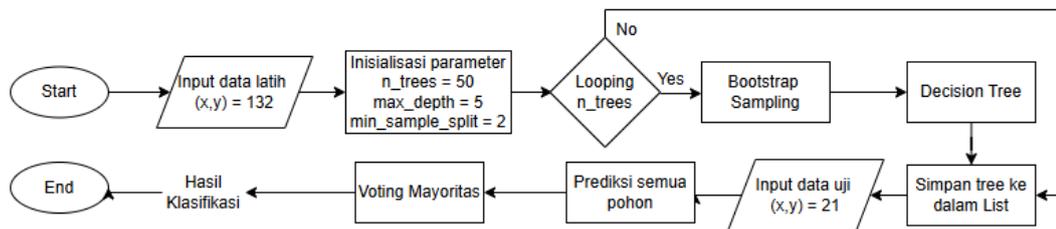
Jika individu menunjukkan gejala kesedihan, maka secara awal ia diklasifikasikan sebagai Normal, namun perlu dilihat indikator lanjutan seperti apakah individu mengalami perasaan euforia yang berlebihan (*euphoric*). Jika tidak, maka dianggap tidak mengalami gangguan signifikan. Namun, jika ya, perlu dilakukan pemeriksaan lebih lanjut terhadap gejala pikiran bunuh diri (*suicidal thoughts*), anoreksia (*anorexia*), penghormatan terhadap otoritas (*authority respect*), dan respons terhadap tekanan seperti mencoba menjelaskan (*try explanation*).

Pada setiap simpul keputusan, terdapat kondisi logis yang mengarahkan ke salah satu dari dua kelas, berdasarkan kombinasi dari beberapa indikator yang mencerminkan status mental individu. Proses ini bersifat rekursif, mengikuti alur percabangan pohon keputusan hingga diperoleh klasifikasi akhir.

Flowchart ini dirancang untuk memvisualisasikan bagaimana sistem klasifikasi berbasis *decision tree* bekerja dalam mengelompokkan individu berdasarkan data psikologis dan perilaku yang diamati. Model ini dapat digunakan sebagai dasar pengambilan keputusan awal dalam deteksi dini gangguan kesehatan mental, khususnya untuk membedakan antara kondisi normal dan depresi

Proses tuning hyperparameter dari algoritma *Random Forest* yang digunakan dalam implementasi ini meliputi jumlah pohon (*n\_trees*), kedalaman maksimal setiap pohon (*max\_depth*), serta jumlah minimal sampel yang diperlukan untuk melakukan split (*min\_samples\_split*). Parameter-parameter ini disesuaikan untuk mengontrol kompleksitas model dan menghindari *overfitting*.

Setelah semua pohon selesai dibangun, setiap pohon akan melakukan prediksi secara independen terhadap data uji. Hasil prediksi dari seluruh pohon kemudian digabungkan melalui proses *voting mayoritas*, di mana kelas yang memperoleh suara terbanyak akan menjadi hasil prediksi akhir. Misalnya, jika tiga pohon memberikan prediksi dengan dua pohon memprediksi kelas “Depresi” dan satu pohon memprediksi kelas “Normal”, maka hasil akhir yang dipilih adalah “Depresi” karena memperoleh suara terbanyak. Pendekatan *ensemble* ini menjadikan *Random Forest* sebagai algoritma yang tidak hanya akurat, tetapi juga tahan terhadap *overfitting*, terutama pada dataset berukuran sedang hingga besar. Dengan demikian, penggunaan *Random Forest* dalam klasifikasi kesehatan mental santri memberikan solusi yang efektif dan andal dalam menghasilkan prediksi berdasarkan pola-pola yang terdapat dalam data.



Gambar 3. 6 Flowchart Random Forest

Flowchart pada Gambar 3.6 menjelaskan alur kerja algoritma Random Forest yang dimulai dengan memasukkan data latih yang terdiri dari 132 data. Setelah itu, dilakukan inisialisasi parameter utama yaitu jumlah pohon keputusan ( $n\_trees$ ) sebanyak 50 pohon, kedalaman maksimum pohon ( $max\_depth$ ) sebesar 5, dan jumlah minimum sampel untuk pemisahan ( $min\_sample\_split$ ) sebanyak 2.

Selanjutnya, proses pembentukan pohon dilakukan secara berulang sebanyak jumlah pohon yang telah ditentukan. Pada tahap ini, dilakukan pemeriksaan apakah jumlah pohon yang telah dibuat masih kurang dari nilai  $n\_trees$ . Jika kondisi “Yes” terpenuhi, maka proses akan dilanjutkan ke tahap bootstrap sampling, yaitu pengambilan data latih secara acak dengan pengembalian untuk membuat subset data. Subset ini kemudian digunakan untuk melatih satu pohon keputusan. Setelah pohon selesai dilatih, pohon tersebut disimpan ke dalam list pohon. Selanjutnya, sistem kembali ke proses pengecekan jumlah pohon yang telah dibuat, dan jika jumlahnya masih belum mencapai 50, proses *looping* akan terus berulang. Namun, apabila kondisi “No” yang terpenuhi, artinya jumlah pohon telah mencapai batas maksimal, maka proses *looping* dihentikan.

.Setelah seluruh pohon terbentuk, proses dilanjutkan ke tahap klasifikasi. Data uji yang terdiri dari 21 data dimasukkan ke dalam model, dan masing-masing

pohon memberikan prediksi terhadap data tersebut. Hasil prediksi dari semua pohon kemudian dikumpulkan dan dilakukan proses voting mayoritas, di mana label kelas yang paling banyak dipilih oleh seluruh pohon akan menjadi hasil klasifikasi akhir. Proses ini menghasilkan keluaran berupa label prediksi untuk data uji. Setelah klasifikasi selesai, proses ditutup dengan tahap akhir (*end*).

Tahapan pelatihan model dengan data latih (*train*) yang digunakan untuk melatih model dibagi menjadi dua, yaitu fitur data latih dan target klasifikasi yang sesuai. Setelah data latih dibagi, dilakukan pembagian proporsi data pengujian untuk tahapan pelatihan model. Setelah pelatihan selesai, model digunakan untuk membuat klasifikasi pada data uji. Hasil klasifikasi kemudian dievaluasi lebih lanjut menggunakan beberapa matrik evaluasi.

### 3.9 Skenario Pengujian

Pemilihan model dalam mengimplementasikan metode *Random Forest* dalam mengklasifikasi kondisi psikologis menggunakan *RandomizedSearchCV* untuk *Random Forest Classifier*. Parameter yang digunakan yaitu  $n\_estimator = 50$  atau 50 pohon keputusan dalam *ensemble (forest)* dan menggunakan parameter  $random\_state = 42$  yang digunakan untuk mengukur random number generator. Selain itu juga menggunakan parameter  $max\_depth = 5$  dalam melakukan pengujian.

Untuk mendapatkan parameter terbaik dari model *Random Forest*, dilakukan proses pencarian otomatis yang disebut *hyperparameter tuning* menggunakan metode *RandomizedSearchCV*. Dalam proses ini, kita memberikan beberapa pilihan nilai untuk setiap parameter penting yang ingin diuji, seperti

jumlah pohon dalam model ( $n\_estimators$ ), kedalaman maksimum pohon ( $max\_depth$ ), jumlah minimum data untuk membagi node ( $min\_samples\_split$ ), jumlah minimum data pada daun pohon ( $min\_samples\_leaf$ ), dan jumlah fitur yang digunakan untuk setiap pemisahan ( $max\_features$ ). Seluruh kombinasi parameter ini dimasukkan ke dalam suatu ruang pencarian.

Namun, karena mencoba semua kombinasi bisa memakan waktu lama, maka digunakan pendekatan pencarian acak. Artinya, dari seluruh kombinasi parameter yang mungkin, sistem hanya mencoba 20 kombinasi secara acak. Untuk memastikan hasilnya tetap akurat, setiap kombinasi diuji menggunakan teknik validasi silang dengan tiga lipatan (3-fold cross-validation), yang membagi data pelatihan menjadi tiga bagian untuk memastikan model diuji secara adil di berbagai subset data.

Selama proses ini, kinerja setiap kombinasi parameter diukur menggunakan akurasi sebagai metrik evaluasi utama. Setelah semua kombinasi selesai diuji, sistem akan memilih satu kombinasi parameter yang menghasilkan akurasi tertinggi sebagai parameter terbaik. Hasil parameter terbaik ini kemudian digunakan untuk membangun model akhir yang akan diterapkan ke data uji.

Parameter-parameter tersebut digunakan dalam penelitian ini setelah dilakukan pengujian sampel data dengan menggunakan beberapa kombinasi parameter seperti dalam tabel berikut.

Tabel 3. 5 *Tuning Hyperparameter*

<b>Tuning Hyperparameter</b>
$n\_estimator = 50, random\_state = 42, max\_depth = 5$
$n\_estimator = 30, random\_state = 42, max\_depth = 3$
$n\_estimator = 50, random\_state = 42, max\_depth = 10$

Pada penelitian ini, data dibagi menjadi dua bagian utama yaitu data latih (*train*) sebesar 80% dan data uji (*test*) sebesar 20%. Data latih digunakan untuk membantu dalam pelatihan model dan data uji digunakan untuk menguji performa model dengan matrik evaluasi menggunakan nilai akurasi, presisi, *recall*, dan *F1-score*. Data-data dalam dataset tersebut akan diolah menggunakan teknik pemrosesan data yang dikenal sebagai *SMOTE (Synthetic Minority Over-sampling Technique)*, yang bertujuan untuk mengatasi permasalahan ketidakseimbangan kelas (*imbalanced data*).

Proses ini akan dibandingkan dengan pengolahan data tanpa penerapan metode *SMOTE*, sehingga dapat diketahui seberapa besar pengaruh teknik *oversampling* tersebut terhadap performa model klasifikasi yang digunakan. Dengan membandingkan kedua pendekatan ini, diharapkan dapat diperoleh gambaran yang lebih komprehensif mengenai efektivitas *SMOTE* dalam meningkatkan akurasi prediksi pada data yang tidak seimbang.

Setelah pengolahan data, tahapan terakhir adalah evaluasi terhadap hasil kinerja model menggunakan algoritma *Random Forest* dalam mengklasifikasi kesehatan mental. Tahapan evaluasi dilakukan dengan menggunakan beberapa matrik, yaitu *Confusion Matrix* yang memiliki fungsi untuk menampilkan keberhasilan dan kesalahan model dalam memprediksi *instance* data dalam setiap kelas. Selain itu juga terdapat matrik *accuracy*, *recall*, *precision*, *f1-score*, dan matrik *convergence plot* untuk melihat perkembangan akurasi selama proses *tuning hyperparameter*.

### 3.10 Evaluasi

Hasil klasifikasi yang didapat dari pelatihan model dievaluasi lebih lanjut menggunakan beberapa matrik. Yang pertama adalah *Confusion Matrix*, yang memberikan gambaran tentang seberapa baik model dapat memprediksi *instance* data dalam kategori benar atau salah. Proses ini melibatkan perhitungan *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Dimana *True Positive* (TP) dan *True Negative* (TN) menggambarkan keakuratan klasifikasi yang sesuai dengan hasil yang aktualnya. Sedangkan *False Positive* (FP) dan *False Negative* (FN) terjadi ketika hasil yang diklasifikasi tidak sesuai dengan kondisi aktualnya (Erdiansyah et al., 2022).

#### 3.10.1 *Confusion Matrix*

*Confusion matrix* adalah salah satu metode evaluasi yang paling umum digunakan untuk menilai performa algoritma klasifikasi. Matriks ini berbentuk tabel dua dimensi yang menyajikan jumlah prediksi yang benar dan salah yang dilakukan oleh model untuk setiap kelas yang ada dalam data. Dalam klasifikasi biner, *confusion matrix* terdiri dari empat komponen utama, yaitu:

- *True Positive* (TP) merupakan jumlah data yang sebenarnya termasuk dalam kelas positif dan berhasil diprediksi dengan benar oleh model sebagai kelas positif. Nilai ini menunjukkan tingkat keberhasilan model dalam mendeteksi kondisi positif yang sesungguhnya.
- *True Negative* (TN) adalah jumlah data yang sebenarnya termasuk dalam kelas negatif dan diprediksi secara tepat oleh model sebagai kelas negatif. Komponen

ini mencerminkan kemampuan model dalam mengenali data negatif secara akurat.

- *False Positive* (FP) adalah jumlah data yang sebenarnya termasuk dalam kelas negatif, tetapi diprediksi secara keliru oleh model sebagai kelas positif. Kesalahan ini sering disebut sebagai *false alarm* atau kesalahan tipe I, dan dapat menimbulkan konsekuensi tergantung pada konteks penerapannya.
- *False Negative* (FN) merupakan jumlah data yang sebenarnya termasuk dalam kelas positif, namun salah diklasifikasikan oleh model sebagai kelas negatif. Kesalahan ini dikenal sebagai kesalahan tipe II, dan pada kasus tertentu dapat berakibat serius karena model gagal mendeteksi kondisi yang seharusnya teridentifikasi sebagai positif.

Tabel 3. 6 Confusion Matrix

<i>Actual Class</i>	<i>Assigned Class</i>	
	<i>Positive</i>	<i>Negative</i>
<i>Positive</i>	<i>True Positive</i>	<i>False Positive</i>
<i>Negative</i>	<i>False Positive</i>	<i>True Negative</i>

Selanjutnya nilai dari komponen dalam confusion matrix akan digunakan untuk menghitung akurasi, presisi, *recall*, dan *f1-score*.

- Akurasi dilakukan untuk memberikan indikasi seberapa baik model dapat memberikan klasifikasi yang akurat. Nilai akurasi dapat dihitung menggunakan persamaan berikut:

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.7)$$

- Matrik selanjutnya adalah presisi yang menunjukkan seberapa baik model dalam mengidentifikasi instance positif. Nilai presisi dapat dihitung menggunakan persamaan berikut:

$$Precision = \frac{TP}{TP + FP} \quad (3.8)$$

- Kemudian recall yang dihitung untuk menunjukkan seberapa baik model dalam mengidentifikasi semua instance positif. Nilai recall dapat dihitung menggunakan persamaan berikut:

$$Recall = \frac{TP}{TP + FN} \quad (3.9)$$

- Selanjutnya, F1 score yang merupakan matrik gabungan yang memperhitungkan keseimbangan antara presisi dan recall. Nilai F1 score dapat dihitung menggunakan persamaan berikut:

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3.10)$$

Tahapan terakhir adalah laporan klasifikasi yang menampilkan sejumlah matrik evaluasi untuk setiap kelas target, termasuk *presisi*, *recall*, dan *F1 score*. Dalam kasus klasifikasi multi-kelas, struktur confusion matrix akan berbentuk matriks persegi dengan ukuran  $n \times n$ , di mana  $n$  adalah jumlah kelas. Setiap baris pada matriks menunjukkan jumlah data aktual dari kelas tertentu, dan setiap kolom menunjukkan jumlah prediksi yang dibuat untuk kelas tersebut. Dengan demikian, elemen diagonal pada matriks menunjukkan jumlah prediksi yang benar, sedangkan elemen di luar diagonal menunjukkan kesalahan klasifikasi antar kelas.

*Confusion matrix* menjadi dasar perhitungan berbagai metrik evaluasi penting seperti akurasi, presisi, *recall*, dan *f1-score*. Akurasi menggambarkan proporsi keseluruhan prediksi yang benar, sedangkan presisi mengukur ketepatan model dalam memprediksi suatu kelas. *Recall* mengukur sejauh mana model mampu menemukan semua instance dari kelas tertentu, dan *f1-score* merupakan rata-rata harmonis antara presisi dan recall. Keempat metrik ini digunakan secara komplementer untuk memberikan gambaran menyeluruh mengenai kinerja model klasifikasi, khususnya dalam situasi data yang tidak seimbang atau memiliki lebih dari dua kelas.

Penggunaan *confusion matrix* sangat penting karena tidak hanya menunjukkan tingkat keberhasilan model dalam melakukan klasifikasi, tetapi juga memperlihatkan kelemahan spesifik model dalam mengenali kelas tertentu. Hal ini sangat berguna dalam penelitian berbasis data riil, seperti klasifikasi kondisi kesehatan mental, di mana pemahaman terhadap jenis kesalahan klasifikasi menjadi krusial dalam pengambilan keputusan lebih lanjut (Tharwat, 2018)

## BAB IV

### HASIL DAN PEMBAHASAN

#### 4.1 Hasil *Exploratory Data Analysis*

Peneliti memvisualisasikan hubungan antar variabel gejala dengan diagnosis pada tahap ini. Visualisasi yang digunakan adalah stacked histogram untuk menggambarkan variabel gejala dan clustermap untuk memvisualisasikan hubungan antar variabel.

##### 4.1.1 *Stacked Histogram*

*Stacked* histogram menampilkan kumpulan visualisasi distribusi data dari beberapa variabel psikologis yang diperoleh dari hasil kuesioner. Setiap subplot menunjukkan distribusi masing-masing variabel berdasarkan dua kategori dari label "*Expert Diagnose*", yaitu 0 (tidak terdiagnosis gangguan) dan 1 (terdiagnosis gangguan). Secara umum, grafik-grafik pada *stacked* histogram menggunakan plot gabungan antara histogram dan estimasi kepadatan kernel (KDE). Warna hijau menunjukkan kelompok yang terdiagnosis (label 1) dan warna biru untuk kelompok yang tidak terdiagnosis (label 0).

Mulai dari subplot pertama, yaitu *Sadness*, responden yang memiliki tingkat kesedihan lebih tinggi cenderung berada dalam kelompok terdiagnosis. Distribusinya lebih menyebar ke arah nilai yang lebih tinggi untuk label 1. Hal ini mengindikasikan bahwa kesedihan adalah salah satu indikator signifikan untuk diagnosis gangguan psikologis. Selanjutnya pada *Euphoric*, pola distribusinya

tampak seimbang antara dua label, namun kelompok dengan diagnosis menunjukkan sedikit pergeseran ke arah nilai yang lebih tinggi.

Untuk variabel *Exhausted*, terlihat bahwa kelompok yang terdiagnosis memiliki distribusi yang cenderung lebih berat di nilai tengah hingga tinggi, yang menandakan bahwa rasa kelelahan yang berlebihan juga bisa menjadi gejala signifikan. Hal serupa juga terlihat pada *Sleep Disorder* dan *Mood Swing*, di mana nilai tinggi dari dua variabel ini lebih banyak dialami oleh mereka yang didiagnosis gangguan psikologis.

*Suicidal thoughts* dan *Anorexia* menunjukkan sebagian besar responden yang tidak mengalami diagnosis (label 0) cenderung tidak memiliki gejala tersebut (bernilai 0), sedangkan pada kelompok terdiagnosis, meski jumlahnya lebih sedikit, distribusinya lebih tersebar hingga nilai 1. Ini menunjukkan bahwa kemunculan gejala seperti pikiran bunuh diri atau anoreksia lebih dominan pada mereka yang mengalami gangguan.

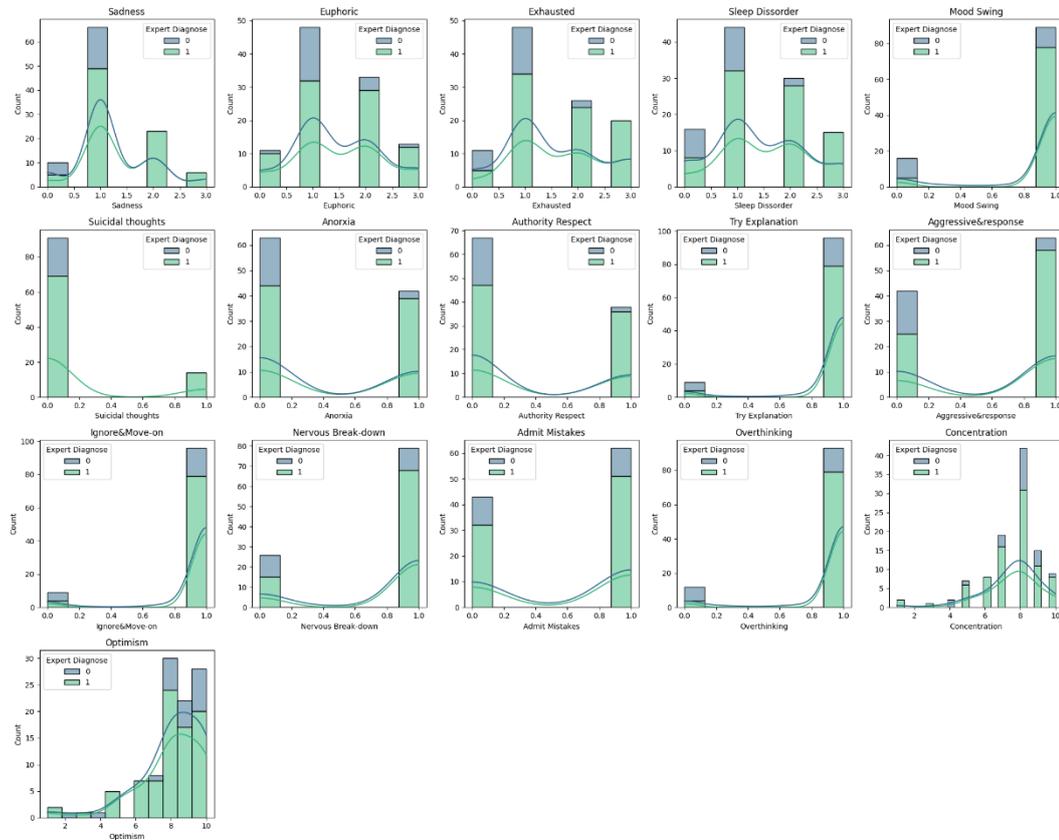
Pada variabel *Authority Respect* dan *Try Explanation*, distribusinya tampak lebih rata dan tidak menunjukkan perbedaan yang signifikan antara dua kelompok. Ini mengindikasikan bahwa variabel ini mungkin kurang relevan dalam membedakan kondisi psikologis antara kelompok normal dan yang mengalami gangguan.

Variabel *Aggressive Response*, *Ignore & Move On*, *Nervous Breakdown*, *Admit Mistakes*, dan *Overthinking*, memperlihatkan perbedaan yang cukup signifikan antara dua kelompok. *Overthinking* dan *Nervous Breakdown* menunjukkan bahwa responden yang terdiagnosis lebih sering mengalami gejala

tersebut dibandingkan dengan yang tidak. Sementara itu, *Admit Mistakes* dan *Ignore & Move On* juga menampakkan kecenderungan tertentu, di mana pola perilaku adaptif ini bisa jadi lebih jarang muncul pada kelompok yang terdiagnosis.

Terakhir, *Optimism* dan *Concentration* merupakan variabel dengan skala nilai yang lebih tinggi (skala 1–10). Terlihat bahwa kelompok yang tidak terdiagnosis memiliki konsentrasi dan optimisme yang lebih tinggi dibandingkan dengan yang terdiagnosis. Ini mendukung pemahaman bahwa penurunan fungsi kognitif merupakan ciri umum dari gangguan psikologis seperti depresi.

Secara keseluruhan, grafik ini sebagai dasar yang kuat untuk seleksi fitur dalam pemodelan machine learning, seperti menggunakan algoritma *Random Forest*, serta bisa digunakan untuk eksplorasi awal terhadap pentingnya masing-masing variabel dalam membedakan kondisi psikologis responden.



Gambar 4. 1 Stacked Histogram

Berdasarkan Gambar 4.1, variabel *Sadness*, *Euphoric*, *Exhausted*, dan *Sleep Disorder* yang berskala 0–3 menunjukkan bahwa semakin tinggi skornya, semakin besar kemungkinan seseorang terdiagnosis gangguan mental. Variabel *Mood Swing*, *Suicidal Thoughts*, dan *Anorexia* berskala 0–1, dan nilai 1 pada variabel ini sangat dominan pada kelompok terdiagnosis, menandakan kuatnya kaitan gejala ini dengan gangguan mental.

Variabel *Authority Respect* dan *Try Explanation* cenderung memiliki nilai rendah pada kelompok terdiagnosis, sedangkan *Aggressive Response* cenderung tinggi, mengindikasikan perubahan perilaku sosial akibat gangguan mental. Untuk

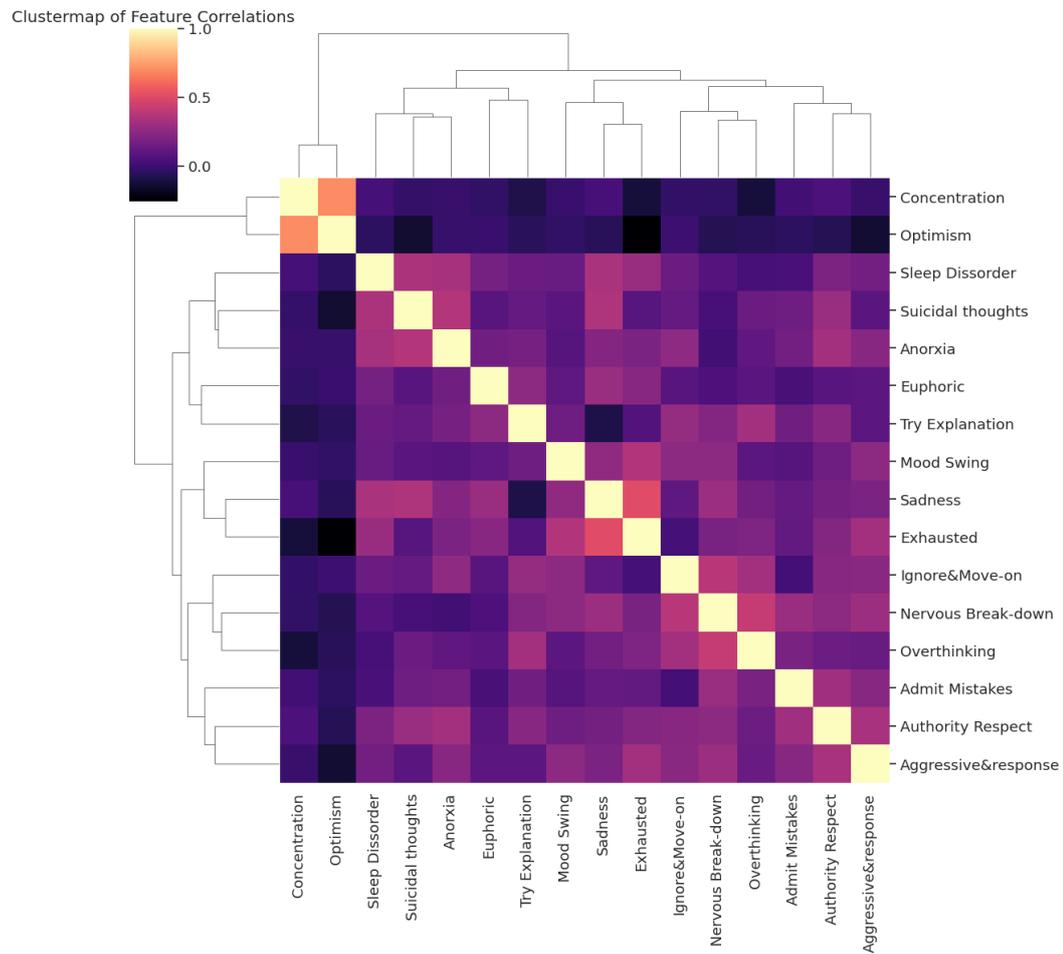
variabel *Ignore & Move On*, *Nervous Breakdown*, dan *Admit Mistakes*, nilai tinggi pada *Nervous Breakdown* dan *Admit Mistakes* banyak ditemukan pada kelompok terdiagnosis, sedangkan *Ignore & Move On* lebih umum pada kelompok normal.

*Overthinking* tampak dominan pada nilai 1 di kelompok terdiagnosis. *Concentration* yang memiliki skala 2–10 lebih tinggi pada kelompok tidak terdiagnosis, mengindikasikan bahwa gangguan mental dapat menurunkan fokus. Terakhir, *Optimism* menunjukkan bahwa individu dengan nilai optimisme rendah cenderung terdiagnosis, sedangkan yang optimis tinggi cenderung tidak terdiagnosis.

#### **4.1.2 Clustermap**

*Clustermap* korelasi antar fitur berdasarkan nilai *pearson correlation coefficient*, dengan tambahan informasi berupa struktur hierarkis kluster yang digambarkan melalui dendrogram di sisi atas dan kiri heatmap. Masing-masing variabel aspek atau gejala psikologis akan diukur korelasinya yang ditandai dengan warna-warna berbeda.

Warna dalam heatmap ini menunjukkan derajat korelasi antara dua fitur. Warna yang lebih terang mendekati kuning menandakan korelasi positif yang kuat (mendekati 1), sementara warna yang lebih gelap keunguan atau hitam menunjukkan korelasi negatif atau korelasi mendekati nol. Warna ini memungkinkan kita untuk mengidentifikasi pasangan variabel mana yang bergerak secara bersamaan dan mana yang tidak memiliki hubungan yang konsisten satu sama lain.



Gambar 4. 2 Clustermap

Dari dendrogram dalam Gambar 4. 2, fitur-fitur yang saling berkorelasi tinggi dikelompokkan secara hierarkis ke dalam satu klaster. Variabel “*Sadness*”, “*Mood Swing*”, dan “*Exhausted*” tampak berada dalam satu kelompok yang relatif dekat. Ini menunjukkan bahwa dalam data, responden yang menunjukkan skor tinggi pada satu variabel tersebut cenderung juga menunjukkan skor tinggi pada variabel lainnya. Secara statistik, korelasi ini dapat diartikan bahwa kondisi emosi seperti kesedihan sering kali berjalan seiring dengan gejala kelelahan dan

perubahan suasana hati, yang memang secara klinis juga saling berkaitan dalam spektrum gangguan *mood*.

Selain itu, terdapat klaster lain yang mencakup fitur seperti “*Overthinking*”, “*Nervous Breakdown*”, dan “*Ignore & Move-on*” yang juga menunjukkan kedekatan korelasi. Klaster ini menggambarkan respons-respons terhadap tekanan atau stres mental yang berkepanjangan. “*Overthinking*” yang cenderung menyebabkan “*Nervous Breakdown*” bisa dianggap sebagai penumpukan beban mental yang tidak terselesaikan, dan perilaku “*Ignore & Move-on*” menjadi bentuk mekanisme *coping* atau justru pengabaian yang maladaptif terhadap masalah psikologis tersebut.

Sementara itu, ada juga fitur-fitur yang memiliki korelasi sangat rendah atau bahkan cenderung berdiri sendiri dalam dendrogram, seperti “*Authority Respect*” atau “*Admit Mistakes*”. Fitur-fitur tersebut dalam konteks data ini tidak berkorelasi secara kuat dan langsung dengan fitur-fitur gejala psikologis lainnya..

Dengan visualisasi pada clustermap ini, identifikasi kelompok-kelompok gejala atau variabel yang berperan bersama dalam membentuk pola psikologis responden menjadi lebih mudah. Hal ini penting untuk diagnosis atau pengembangan model prediksi, karena kita dapat mempertimbangkan variabel-variabel yang saling berkaitan sebagai satu kesatuan ketika membangun fitur atau melakukan interpretasi terhadap hasil klasifikasi. Sebagai contoh, jika sebuah model menunjukkan bahwa “*Mood Swing*” adalah fitur penting dalam mendeteksi kondisi depresi, maka fitur-fitur seperti “*Sadness*” dan “*Exhausted*” yang berada

dalam satu kluster dengannya juga berpotensi memberikan kontribusi besar dalam klasifikasi.

## **4.2 Hasil *Preprocessing* Data**

Penelitian ini menggunakan data hasil penyebaran kuesioner di Pondok Pesantren Al-Hikmah Al-Fathimiyyah dengan 105 data dengan 18 atribut yang berisi teks atau kategorikal. Sehingga perlu dilakukan tahapan *preprocessing* data yang meliputi label *encoding* dan pemilihan fitur supaya dapat diproses menggunakan *machine learning*.

### **4.2.1 Label *Encoding***

Dataset yang digunakan merupakan tipe data teks atau kategorikal. Supaya data tersebut dapat diolah menggunakan machine learning, maka data tersebut harus diubah menjadi data numerical atau yang disebut dengan proses *encoding*. Berikut perbedaan data sebelum dan sesudah dilakukan *encoding*:

Tabel 4. 1 Hasil Encoding

Expert Diagnose	Optimism	Concentration	Overthinking	Admit Mistakes	Nervous Break-down	Ignore&Move-on	Aggressive&Response	Try Explanation	Authority Respect	Anorxia	Suicidal thoughts	Mood Swing	Sleep Disorder	Exhausted	Euphoric	Sadness	Name/Initial
1	9	8	1	0	1	1	1	1	0	0	0	1	0	3	1	1	0
1	8	8	1	0	1	1	1	1	0	0	0	1	1	3	3	3	1
1	6	5	1	0	1	1	1	1	1	0	0	1	1	2	1	2	2
1	10	10	1	0	0	1	1	1	0	0	0	1	0	1	3	0	3
1	6	5	1	0	0	1	1	1	0	1	0	1	2	1	1	1	4
1	7	5	1	0	0	1	0	1	0	0	0	1	1	1	1	1	5
1	8	6	1	0	0	1	0	0	0	0	0	1	1	3	1	2	6
1	8	6	1	1	0	0	0	1	0	0	0	1	0	1	0	1	7
1	10	8	0	0	0	1	1	0	0	0	0	1	2	1	0	1	8
0	9	7	1	0	1	1	1	1	1	1	0	1	1	1	1	1	9
0	9	8	1	1	1	1	0	1	0	0	0	1	0	0	2	1	10

Setelah dilakukan tahap label *encoding*, maka data yang awalnya berupa teks akan berubah menjadi data numerik yang hanya berisi angka seperti pada Tabel 4.1.

#### 4.2.2 Seleksi Fitur

Pada tahap ini, dilakukan pemisahan antara variabel independen dan variabel dependen yang akan digunakan dalam proses klasifikasi. Dataset semula terdiri dari 18 kolom, salah satunya adalah kolom *Name/Initial* yang hanya berfungsi sebagai identitas responden dan tidak relevan terhadap proses pemodelan, sehingga dihilangkan. Kemudian, kolom *Expert Diagnose* dipilih sebagai variabel target atau label yang ingin diprediksi. Dengan mengeluarkan kedua kolom tersebut (*Name/Initial* dan *Expert Diagnose*), tersisa 16 kolom yang berperan sebagai fitur (disimpan dalam variabel  $x$ ), sedangkan nilai dari *Expert Diagnose* disimpan dalam variabel  $y$  sebagai target klasifikasi.

Fitur *Authority Respect* dan *Admit Mistakes* memiliki korelasi yang rendah dari hasil EDA terhadap fitur lainnya serta kontribusi numerik (*feature importance*) yang tergolong kecil, kedua fitur ini tetap dipertahankan dalam proses pemodelan karena nilai korelasi tidak selalu merepresentasikan nilai semantik atau psikologis dari suatu variabel, khususnya dalam konteks klasifikasi kesehatan mental. Selain itu, algoritma Random Forest mampu menangani variabel-variabel dengan kontribusi kecil tanpa menyebabkan degradasi performa model secara signifikan. Oleh karena itu, fitur-fitur tersebut tetap disertakan untuk menjaga kelengkapan dimensi psikologis dalam analisis, sekaligus menghindari penghilangan informasi yang mungkin relevan terhadap kelas minoritas yang lebih sulit dikenali oleh model.

### 4.3 Hasil Pemisahan Data

Data dipisah menjadi dua bagian, yaitu data *training* dan *testing*. Data dipisah dengan perbandingan 80:20. Label  $x$  sebagai fitur dan  $y$  sebagai target. Berikut perbandingan data setelah dan sebelum *splitting*:

Tabel 4. 2 Hasil Splitting

Dataset	Jumlah Sampel	Dimensi Fitur	Keterangan
$x$ (sebelum)	105	16	Data fitur awal
$y$ (sebelum)	105	-	Label/kelas awal
$x_{train}$	84	16	80% dari data, untuk pelatihan
$y_{train}$	84	-	Label dari data pelatihan
$x_{test}$	21	16	20% dari data, untuk pengujian
$y_{test}$	21	-	Label dari data pengujian

Tabel 4. 2 menunjukkan hasil pembagian dataset menjadi data latih (*training*) dan data uji (*testing*). Sebelum dibagi, dataset memiliki 105 sampel (baris) dengan 16 fitur, dan 105 label target. Setelah proses `train_test_split` dengan parameter `test_size=0.2`, data dibagi menjadi 84 sampel (80%) untuk pelatihan dan 21 sampel (20%) untuk pengujian. Dimensi fitur tetap 16 untuk  $X_{train}$  dan  $X_{test}$ . Proses ini juga menggunakan stratifikasi, artinya distribusi kelas pada label tetap seimbang antara data latih dan data uji, sehingga hasil pelatihan dan evaluasi model akan lebih adil dan representatif.

### 4.4 Hasil SMOTE

Dataset yang digunakan mengalami ketidakseimbangan atau *imbalanced*, sehingga perlu diseimbangkan menggunakan teknik SMOTE supaya model lebih

akurat. Dataset setelah proses splitting dengan jumlah awal yaitu 84 data untuk pelatihan ( $X_{train}$ ,  $y_{train}$ ) dan 21 data untuk pengujian ( $X_{test}$ ,  $y_{test}$ ). Data pelatihan mengalami ketidakseimbangan kelas. Secara spesifik, distribusi label pada  $y_{train}$  menunjukkan bahwa hanya terdapat 18 data untuk kelas 0 (minoritas), sedangkan kelas 1 (mayoritas) memiliki 66 data. Model akan lebih banyak mengenali pola dari kelas 1 dan berisiko mengabaikan atau gagal mengenali pola dari kelas 0. Distribusi pada  $y_{test}$  mencerminkan pola yang sama, yaitu 4 data untuk kelas 0 dan 17 data untuk kelas 1.

Distribusi Kelas Sebelum SMOTE:		
Kelas	Jumlah ( $y_{train}$ )	Jumlah ( $y_{test}$ )
0	18	4
1	66	17
Total	84	21

Distribusi Kelas Setelah SMOTE:		
Kelas	Jumlah ( $y_{train\_resampled}$ )	
0	66	
1	66	
Total	132	

Gambar 4. 3 Distribusi Kelas

Pada Gambar 4.3 setelah SMOTE diterapkan, data pelatihan bertambah dari 84 menjadi 132 sampel. Hal ini terjadi karena jumlah data untuk kelas 0 yang sebelumnya hanya 18, ditambahkan hingga seimbang dengan kelas 1, yaitu masing-masing menjadi 66 data. Jumlah fitur tetap sama, yaitu 16, sehingga  $X_{train\_resampled}$  memiliki bentuk (132, 16), dan  $y_{train\_resampled}$  memiliki 132 label. Dengan distribusi kelas yang seimbang (66:66), model pelatihan tidak lagi dominan pada kelas mayoritas.

SMOTE (*Synthetic Minority Over-sampling Technique*) hanya pada data pelatihan, karena tujuan utama SMOTE adalah menyeimbangkan distribusi kelas

selama proses pelatihan agar model dapat mengenali kedua kelas secara adil. SMOTE bekerja dengan menciptakan data sintetis baru pada kelas minoritas berdasarkan sampel yang ada, bukan dengan menyalin data, melainkan membuat variasi baru dari data yang serupa. Untuk mengintegrasikan proses *oversampling* dan pemodelan secara otomatis serta menghindari kebocoran data uji, digunakan *pipeline* dari pustaka *imblearn*, yang menggabungkan SMOTE dan Random Forest dalam satu alur kerja terstruktur. Pipeline ini memastikan bahwa SMOTE hanya diterapkan pada data pelatihan dan tidak memengaruhi data uji, sehingga proses evaluasi tetap valid dan tidak bias. Penerapan SMOTE secara otomatis hanya saat model dilatih (*fit()*), tanpa menyentuh data uji (*X\_test*). Dengan cara ini, proses pelatihan tetap konsisten, efisien, serta aman dari risiko *data leakage*.

## 4.5 Hasil Uji Coba

Pada penelitian ini terdapat dua skenario uji coba, pertama model dilatih menggunakan data yang telah dilakukan teknik SMOTE dan kedua dataset asli tanpa teknik SMOTE dengan *hyperparameter tuning* berbeda pada masing-masing skenario.

### 4.5.1 Hasil Uji Coba Skenario 1

Skenario 1 pada penelitian ini menggunakan data *training* yang telah dilakukan proses SMOTE dengan jumlah masing-masing data adalah 66 untuk kelas 0 dan 1. *Hyperparameter tuning* yang digunakan adalah *class\_weight='balanced'*, *max\_depth=5*, *min\_samples\_leaf=2*, *n\_estimators=50*, *random\_state=42* dari 20

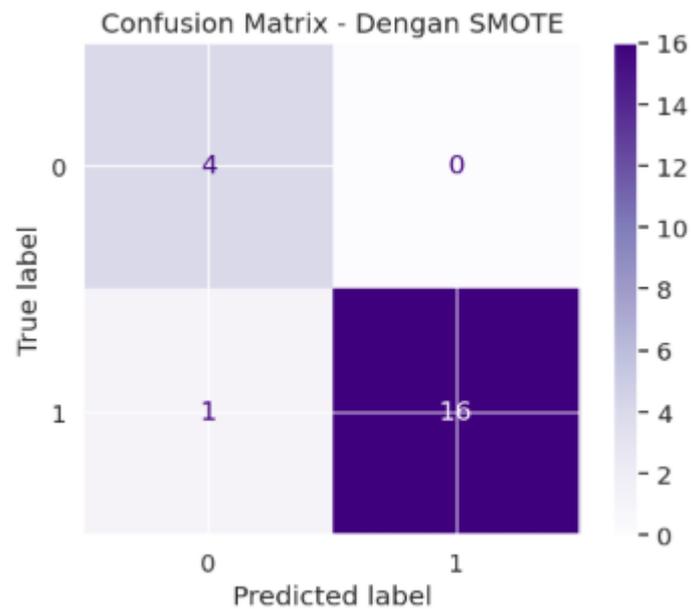
percobaan, parameter yang terbaik yang digunakan dan dipilih menggunakan fungsi *rs\_clf.best\_params*.

Tabel 4. 3 Iterasi Hyperparameter *Tuning*

<b>Iterasi ke-</b>	<b>n_estimator</b>	<b>min_samples_split</b>	<b>min_sample_leaf</b>	<b>max_depth</b>	<b>Akurasi</b>	<b>Precision</b>	<b>Recall</b>	<b>F1 Score</b>
1	10	5	2	3	90%	94%	90%	91%
2	10	5	4	10	90%	90%	90%	90%
3	30	5	4	5	95%	96%	95%	95%
4	50	10	2	5	90%	90%	90%	90%
5	10	5	2	5	86%	87%	86%	86%
6	10	5	4	3	90%	94%	90%	91%
7	10	10	4	10	90%	90%	90%	90%
8	30	10	2	5	95%	96%	95%	95%
9	50	5	2	3	86%	87%	86%	86%
10	50	10	4	3	95%	96%	95%	95%
11	50	10	2	10	90%	90%	90%	90%
12	50	5	4	10	95%	96%	95%	95%
13	50	5	4	5	95%	96%	95%	95%
14	10	5	4	5	95%	96%	95%	95%
15	10	10	2	5	86%	87%	86%	86%
16	30	10	4	10	90%	90%	90%	90%
17	30	5	2	3	95%	96%	95%	95%
18	50	5	2	10	86%	85%	86%	85%
19	50	5	2	5	90%	90%	90%	90%
20	30	10	2	3	95%	96%	95%	95%

Tabel 4.3 menampilkan hasil dari proses hyperparameter tuning untuk algoritma Random Forest yang dilakukan sebanyak 20 iterasi. Setiap iterasi menguji kombinasi nilai yang berbeda untuk parameter *n\_estimators*, *min\_samples\_split*, *min\_samples\_leaf*, dan *max\_depth*, kemudian dievaluasi menggunakan metrik akurasi, precision, recall, dan F1-score. Kombinasi nilai parameter dari *n\_estimators* sebesar 30 atau 50, *min\_samples\_split* sebesar 5, *min\_samples\_leaf* sebesar 2 atau 4, dan *max\_depth* antara 3 hingga 5 cenderung menghasilkan performa model yang lebih baik. Hal ini dapat dilihat dari beberapa iterasi, seperti iterasi ke-3, ke-8, ke-10, ke-12, ke-13, ke-14, ke-17, dan ke-20 yang mampu mencapai nilai akurasi, *precision*, *recall*, dan *F1-score* sebesar 95% hingga 96%.

Sebaliknya, kombinasi parameter yang menggunakan *n\_estimators* sebesar 10 dan *max\_depth* yang terlalu rendah atau terlalu tinggi tampaknya menghasilkan performa yang kurang optimal, dengan akurasi hanya sekitar 86% hingga 90%. Secara keseluruhan, proses tuning ini menunjukkan bahwa pemilihan kombinasi parameter yang tepat sangat berpengaruh terhadap kinerja model Random Forest dalam melakukan klasifikasi data. Parameter yang digunakan merupakan iterasi ke-4, karena lebih stabil dan rata-ratanya tertinggi di semua *fold*. Setelah proses hyperparameter tuning, model akan digunakan dalam klasifikasi kesehatan mental dan hasilnya akan dievaluasi menggunakan *confusion matrix*.



Gambar 4. 4 Confusion Matrix Skenario 1

Pada Gambar 4.4, sumbu vertikal menunjukkan *true label* (label sebenarnya), sedangkan sumbu horizontal menunjukkan *predicted label* (label yang diprediksi oleh model). *Confusion matrix* ini merepresentasikan performa model setelah diterapkan metode SMOTE (*Synthetic Minority Oversampling Technique*) untuk menyeimbangkan distribusi kelas.

Berdasarkan gambar tersebut, dapat disajikan informasi confusion matrix dalam tabel berikut:

Tabel 4. 4 Confusion Matrix Uji Coba 2

	Normal	Depresi
Normal	4 ( <i>True Negative</i> )	0 ( <i>False Positive</i> )
Depresi	1 ( <i>False Negarive</i> )	16 ( <i>True Positive</i> )

- 16 data depresi berhasil diklasifikasikan dengan benar sebagai depresi (*True Positive*).
- 1 data depresi salah diklasifikasikan sebagai normal (*False Negative*).
- 4 data normal berhasil diklasifikasikan sebagai normal (*True Negative*).

- Tidak ada data normal yang salah diklasifikasikan sebagai depresi (*False Positive = 0*).
- 2 data normal yang salah diklasifikasikan sebagai depresi (*False Positive*).

Model menunjukkan performa yang sangat baik dalam mendeteksi kasus depresi dengan *Recall = 100%*, namun masih memiliki kekurangan berupa *false positive*, di mana beberapa data normal salah diprediksi sebagai depresi. Hal ini menunjukkan model cenderung lebih “sensitif” terhadap kasus depresi, yang dalam konteks tertentu bisa jadi menguntungkan karena tidak ada kasus depresi yang terlewat, namun tetap perlu diimbangi agar tidak menimbulkan prediksi salah pada individu normal.

#### 4.6 Hasil Uji Coba Skenario 2

Pada skenario 2, model *Random Forest* menggunakan data asli tanpa teknik SMOTE. Data yang digunakan berjumlah 21 data (4 data pada kelas 0 dan 17 data pada kelas 1). *Tuning hyperparameter* yang digunakan adalah *n\_estimators: 50*, *min\_samples\_split: 2*, *max\_features: sqrt*, *max\_depth: 5*.

Tabel 4. 5 Iterasi Hyperparameter *Tuning 2*

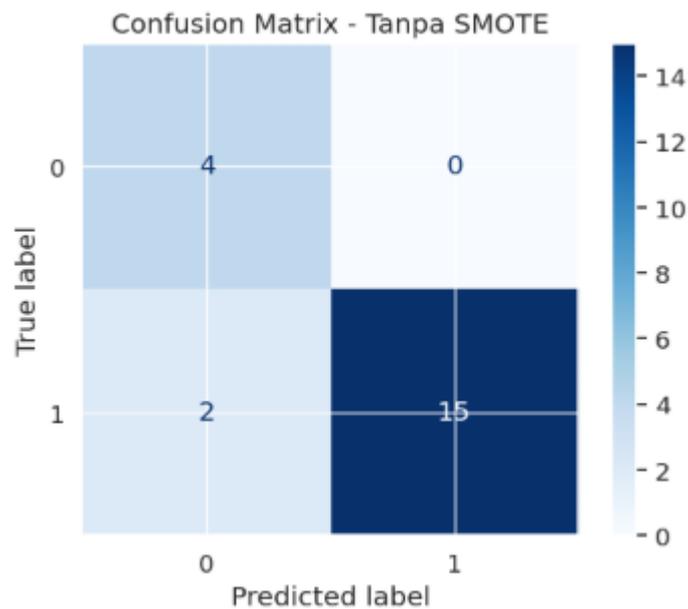
Iterasi ke-	n_estimator	min_sample_split	min_sample_leaf	max_depth	Akurasi	Presisi	Recall	F1 Score
1	10	5	2	3	90%	94%	90%	91%
2	10	5	4	10	90%	94%	90%	91%
3	30	5	4	5	95%	96%	95%	95%
4	50	10	2	5	95%	96%	95%	95%
5	10	5	2	5	95%	96%	95%	95%
6	10	5	4	3	95%	96%	95%	95%
7	10	10	4	10	90%	94%	90%	91%
8	30	10	2	5	95%	96%	95%	95%
9	50	5	2	3	90%	90%	90%	90%
10	50	10	4	3	95%	96%	95%	95%

11	50	10	2	10	95%	96%	95%	95%
12	50	5	4	10	95%	96%	95%	95%
13	50	5	4	5	95%	96%	95%	95%
14	10	5	4	5	95%	96%	95%	95%
15	10	10	2	5	90%	94%	90%	91%
16	30	10	4	10	95%	96%	95%	95%
17	30	5	2	3	95%	96%	95%	95%
18	50	5	2	10	100%	100%	100%	100%
19	50	5	2	5	95%	96%	95%	95%
20	30	10	2	3	95%	96%	95%	95%

Proses *tuning hyperparameter* pada model *Random Forest* dilakukan menggunakan metode *RandomizedSearchCV* sebanyak 20 iterasi. Tujuan dari proses ini adalah untuk memperoleh kombinasi parameter yang memberikan hasil klasifikasi terbaik berdasarkan metrik evaluasi, yaitu akurasi, presisi, recall, dan F1-score. Adapun parameter yang dituning meliputi jumlah pohon (*n\_estimators*), kedalaman maksimum pohon (*max\_depth*), jumlah minimum sampel untuk membagi simpul (*min\_samples\_split*), dan jumlah minimum sampel pada daun pohon (*min\_samples\_leaf*).

Hasil evaluasi menunjukkan bahwa sebagian besar kombinasi parameter menghasilkan performa yang sangat baik, dengan nilai akurasi berkisar antara 90% hingga 95%. Namun, dari keseluruhan iterasi yang dilakukan, terdapat satu kombinasi parameter yang memberikan hasil evaluasi paling tinggi, yakni pada iterasi ke-19. Pada iterasi tersebut, model memperoleh skor akurasi, presisi, recall, dan F1-score sebesar 95%. Hal ini menunjukkan bahwa model mampu mengklasifikasikan seluruh data uji dengan sangat baik tanpa kesalahan prediksi. Oleh karena itu, kombinasi parameter pada iterasi ke-19 dipilih sebagai hasil tuning

terbaik. Meskipun demikian, performa model yang sempurna ini perlu dianalisis lebih lanjut. Skor evaluasi yang sangat tinggi bisa menjadi indikasi adanya *overfitting*, yaitu kondisi di mana model terlalu menyesuaikan diri dengan data pelatihan dan tidak mampu melakukan generalisasi dengan baik terhadap data baru. Hal ini terutama perlu diwaspadai jika jumlah data uji yang digunakan relatif sedikit atau memiliki kemiripan yang tinggi dengan data pelatihan. Untuk memastikan kestabilan model, evaluasi tambahan menggunakan data lain atau validasi silang secara menyeluruh sangat disarankan.



Gambar 4. 4 Confusion Matrix Skenario 2

Pada Gambar 4. 4, sumbu vertikal menunjukkan nilai label yang sebenarnya (*true label*), sedangkan sumbu horizontal menunjukkan label yang diprediksi oleh model. Matriks ini terdiri dari empat sel utama yang merepresentasikan jumlah prediksi benar dan salah dari model terhadap masing-masing kelas. Berdasarkan gambar tersebut, informasi *confusion matrix* dapat dijabarkan dalam tabel berikut:

Tabel 4. 6 Confusion Matrix Uji Coba 1

	<b>Normal</b>	<b>Depresi</b>
<b>Normal</b>	4 ( <i>True Negative</i> )	0 ( <i>False Positive</i> )
<b>Depresi</b>	2 ( <i>False Negative</i> )	15 ( <i>True Positive</i> )

Berdasarkan isi tabel tersebut, dapat disimpulkan:

- 15 data depresi berhasil diprediksi dengan benar sebagai depresi (*True Positive*).
- 2 data depresi salah diklasifikasikan sebagai normal (*False Negative*).
- 4 data normal berhasil diprediksi dengan benar sebagai normal (*True Negative*).
- Tidak ada data normal yang salah diklasifikasikan sebagai depresi (*False Positive = 0*).

Model tanpa penerapan SMOTE masih menunjukkan performa yang cukup baik, dengan akurasi sekitar 90,47% dan *F1-score* sebesar 94,12%. Namun, terdapat dua kasus *false negative* (data depresi yang diklasifikasikan sebagai normal), yang menunjukkan bahwa model sedikit kesulitan mengenali seluruh data depresi dengan benar. Hal ini dapat diatasi dengan metode penyeimbangan data seperti SMOTE, yang bertujuan untuk meningkatkan sensitivitas terhadap kelas minoritas.

#### 4.7 Pembahasan

Pada skenario pertama, model menunjukkan performa klasifikasi yang baik secara keseluruhan dengan tingkat akurasi sebesar 90%. Untuk kelas 0, model memperoleh nilai *precision* dan *recall* yang sama, yaitu sebesar 0.75. Artinya, sebanyak 75% dari prediksi kelas 0 benar, dan model juga berhasil mengenali 75%

dari seluruh data aktual kelas 0. Nilai *F1-score* yang juga sebesar 0.75 mencerminkan keseimbangan antara kemampuan model dalam mengenali dan memprediksi kelas tersebut, meskipun performanya masih belum sempurna.

Sementara itu, untuk kelas 1, model menunjukkan kinerja yang sangat baik, dengan *precision* dan *recall* masing-masing sebesar 0.94. Ini berarti bahwa sebagian besar prediksi kelas 1 benar, dan hampir seluruh data aktual kelas 1 berhasil dikenali dengan tepat. Nilai *F1-score* sebesar 0.94 menunjukkan bahwa model sangat andal dalam mengklasifikasikan kelas mayoritas ini.

Nilai *macro average F1-score* sebesar 0.85 mengindikasikan bahwa model memiliki kinerja yang cukup merata pada kedua kelas, meskipun ada ketimpangan jumlah data antar kelas. Adapun nilai *weighted average F1-score* yang juga sebesar 0.90 menunjukkan bahwa performa model secara keseluruhan sangat baik dan stabil, terutama karena mempertimbangkan proporsi jumlah data yang lebih besar pada kelas mayoritas.

Classification Report:				
	precision	recall	f1-score	support
0	0.75	0.75	0.75	4
1	0.94	0.94	0.94	17
accuracy			0.90	21
macro avg	0.85	0.85	0.85	21
weighted avg	0.90	0.90	0.90	21

Gambar 4. 5 *Classification Report 1*

Sedangkan pada skenario kedua, model klasifikasi berhasil mencapai akurasi sebesar 90%, yang menunjukkan bahwa secara umum model mampu mengklasifikasikan data dengan cukup baik. Untuk kelas 0, *precision* yang diperoleh sebesar 0.67 dan *recall* mencapai 1.00. Hal ini menunjukkan bahwa

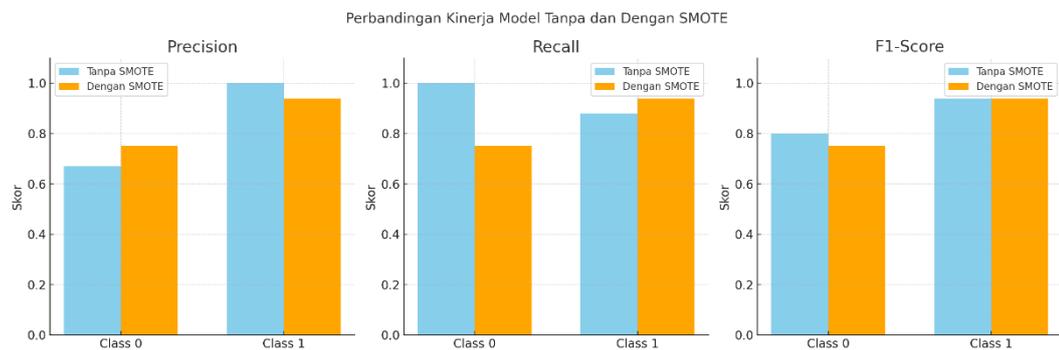
semua data aktual dari kelas 0 berhasil dikenali dengan benar oleh model (tidak ada *false negative*). Namun, karena terdapat beberapa data dari kelas lain yang salah diklasifikasikan sebagai kelas 0 (*false positive*), maka nilai *precision*-nya menjadi lebih rendah. Nilai *F1-score* sebesar 0.80 menunjukkan bahwa meskipun *recall*-nya sempurna, ketidakseimbangan *precision* memengaruhi keseluruhan kinerja model terhadap kelas 0.

Sementara itu, pada kelas 1, model mencatatkan *precision* sempurna sebesar 1.00, yang berarti seluruh prediksi kelas 1 benar-benar berasal dari data aktual kelas tersebut (tidak ada *false positive*). Namun, *recall* yang sebesar 0.88 menunjukkan bahwa masih terdapat sebagian kecil data aktual kelas 1 yang tidak berhasil dikenali oleh model (terjadi *false negative*). Meskipun demikian, nilai *F1-score* yang tinggi, yaitu 0.94, menunjukkan bahwa model memiliki performa yang sangat baik dalam mengklasifikasikan kelas mayoritas ini.

Nilai *macro average F1-score* sebesar 0.87 memperlihatkan bahwa kinerja model terhadap kedua kelas cukup baik dan relatif seimbang. Sementara itu, nilai *weighted average F1-score* sebesar 0.91 menunjukkan bahwa secara keseluruhan model bekerja sangat efektif, terutama karena tingginya kontribusi kinerja pada kelas mayoritas terhadap hasil akhir.

	precision	recall	f1-score	support
0	0.67	1.00	0.80	4
1	1.00	0.88	0.94	17
accuracy			0.90	21
macro avg	0.83	0.94	0.87	21
weighted avg	0.94	0.90	0.91	21

Gambar 4. 6 Classification Report 2



Gambar 4. 7 Perbandingan Model

Berdasarkan Gambar 4.6, penerapan teknik SMOTE (*Synthetic Minority Over-sampling Technique*) menunjukkan adanya perubahan dalam kinerja sistem, khususnya pada klasifikasi data yang tidak seimbang. Hasil evaluasi menunjukkan bahwa model tanpa SMOTE mencapai akurasi sebesar 90%, namun terdapat perbedaan yang mencolok dalam performa antar kelas. Kelas 0 (minoritas) memiliki recall sebesar 1.00, menunjukkan bahwa seluruh data pada kelas ini berhasil dikenali, namun precision-nya hanya sebesar 0.67, yang mengindikasikan bahwa terdapat sejumlah prediksi kelas 0 yang berasal dari kelas lain (*false positive*). Sebaliknya, kelas 1 (mayoritas) menunjukkan precision sebesar 1.00, tetapi *recall*-nya hanya 0.88, mengindikasikan adanya data kelas 1 yang tidak berhasil terdeteksi.

Setelah penerapan SMOTE, performa antar kelas menjadi lebih seimbang. Precision dan recall untuk kelas 0 meningkat menjadi masing-masing 0.75, menunjukkan penurunan jumlah *false positive* sekaligus kemampuan model dalam mengenali kelas minoritas secara lebih proporsional. Untuk kelas mayoritas (kelas 1), nilai *precision* dan *recall* tetap berada pada angka 0.94, yang mengindikasikan bahwa performa klasifikasi pada kelas tersebut tetap konsisten setelah

penyeimbangan data dilakukan. *F1-score* untuk masing-masing kelas, yaitu 0.75 untuk kelas 0 dan 0.94 untuk kelas 1, juga menunjukkan peningkatan kesetaraan performa antar kelas.

Nilai macro average *F1-score* tanpa SMOTE tercatat sebesar 0.87, sedikit lebih tinggi dibandingkan dengan model dengan SMOTE, yaitu 0.85. Demikian pula, weighted average *F1-score* tanpa SMOTE sebesar 0.91 dibandingkan dengan 0.90 pada model dengan SMOTE. Perbedaan ini tergolong kecil dan menunjukkan bahwa performa keseluruhan model relatif stabil pada kedua pendekatan. Namun, distribusi performa antar kelas pada model dengan SMOTE menunjukkan perbaikan dalam hal keseimbangan metrik klasifikasi, terutama pada kelas minoritas. Penerapan SMOTE berkontribusi terhadap pemerataan performa model dalam mengklasifikasikan kelas dengan jumlah data yang berbeda secara proporsional. Perubahan ini dapat menjadi pertimbangan dalam pemilihan model apabila keseimbangan performa antar kelas menjadi prioritas analisis.

#### 4.8 Integrasi Islam

Islam menganjurkan untuk tidak berlarut-larut dalam kesedihan, seperti kesedihan mendalam Nabi Muhammad atas penolakan kaumnya terhadap dakwah yang beliau sampaikan. Bahkan, Allah menyampaikan bahwa kesedihan itu bisa begitu dalam hingga membahayakan diri beliau sendiri seperti yang diterangkan dalam Surat Al-Kahfi ayat 6:

فَلَعَلَّكَ بَاخِعٌ مُّتَّفِسِكٌ عَلَيَّ ۖ ءَاثَرَهُمْ إِن لَّمْ يُؤْمِنُوا بِهَذَا ٱلْحَدِيثِ ٱسْفَا

“Maka (apakah) barangkali engkau (Muhammad) akan membunuh dirimu karena bersedih hati sesudah mereka berpaling, sekiranya mereka tidak beriman kepada keterangan ini (Al-Qur'an)” (QS. Al-Kahfi:6).

Dalam kitab Tafsir ibn Katsir, kata “*bākhi‘ nafsaka*” dalam ayat ini memiliki arti “membunuh dirimu sendiri” akibat kesedihanmu atas diri mereka. Dalam ayat tersebut, Allah melarang Nabi Muhammad untuk membinasakan diri karena putus asa dan kecewa terhadap mereka (Al-Sheikh, 1994). Ayat tersebut menunjukkan sebuah kondisi tekanan batin, di mana seseorang merasa terbebani secara emosional karena memikirkan keadaan orang lain yang tidak sesuai dengan harapan atau nilai yang ia perjuangkan. Dalam psikologi modern, kondisi ini serupa dengan bentuk distress emosional, kelelahan mental, bahkan indikasi awal dari gangguan depresi atau keputusasaan. Dalam ayat ini, Allah SWT mengingatkan Rasul saw agar tidak bersedih hati, hingga merusak kesehatan dirinya, hanya karena kaumnya tidak mau beriman kepada Al-Qur’an dan kenabiannya. Hal demikian itu tidak patut membuat Nabi sedih karena tugas beliau hanyalah menyampaikan wahyu Ilahi kepada mereka, sedangkan kesediaan jiwa mereka untuk menerima kebenaran ayat-ayat tersebut tergantung kepada petunjuk Allah swt (tafsiralquran.id, 2021).

Jika dikaitkan dengan indikator-indikator dalam klasifikasi kesehatan mental, ayat ini dapat memberikan pemahaman bahwa kesedihan mendalam, rasa lelah akibat terus-menerus memikirkan keadaan orang lain, serta keinginan besar untuk memperbaiki sesuatu yang di luar kendali seseorang bisa menjadi gejala awal dari gangguan psikologis tertentu. Dalam hal ini, beberapa fitur yang umum digunakan dalam klasifikasi kondisi psikologis seperti *mood swing*, *sadness*, *overthinking*, *exhausted*, hingga *suicidal thoughts* dapat dipahami relevansinya

melalui pendekatan tematik dari ayat tersebut. Ayat ini juga memberikan pelajaran penting, bahwa dalam *Muamalah ma'a An-nas* atau hubungan sesama manusia, seseorang tetap perlu menjaga batas dan keseimbangan agar tidak merusak dirinya sendiri secara mental maupun fisik ketika putus asa atau mengalami kekecewaan atas perbuatan orang lain terhadap diri kita. Seseorang harus tetap menjaga batas, proporsi, dan keseimbangan emosional dalam menghadapi sikap atau perlakuan orang lain. Sikap empati dan perhatian terhadap sesama memang dianjurkan, tetapi tidak boleh sampai mengorbankan kesehatan mental, emosional, maupun fisik diri sendiri karena kecewa atau putus asa atas respons negatif orang lain. Dalam praktiknya, *muamalah* yang sehat menuntut kita untuk tetap bersikap baik, adil, dan penuh kasih, namun juga harus memiliki keteguhan hati dan kejelasan batas agar tidak terlarut dalam kesedihan yang berlebihan. Sehingga tetap mampu menjalankan peran sosial dan ibadah dengan utuh, tanpa terbebani oleh ekspektasi yang tidak realistis terhadap perubahan sikap orang lain yang berada di luar kendali kita.

Nabi Muhammad SAW, seorang manusia paling mulia mendapatkan peringatan langsung dari Allah agar tidak membiarkan kesedihan atas orang lain membuat beliau jatuh dalam kondisi yang membahayakan dirinya. Dari sini, Islam memberikan sinyal yang jelas bahwa kesehatan mental merupakan aspek penting yang perlu dijaga, baik melalui pendekatan spiritual maupun pendekatan rasional. Ketika terjadi suatu kesedihan dalam diri, solusi yang baik bukanlah untuk mengakhiri hidup tetapi menghilangkan kesedihan itu secara perlahan. Dalam surat An-nisa ayat 29 diterangkan:

وَلَا تَقْتُلُوا أَنْفُسَكُمْ ۚ إِنَّ اللَّهَ كَانَ بِكُمْ رَحِيمًا

"Dan janganlah kamu membunuh dirimu; sesungguhnya Allah adalah Maha Penyayang kepadamu." (QS. An-Nisa: 29).

Dalam ayat tersebut terdapat kalimat “dan janganlah kamu membunuh dirimu”. Dalam kitab tafsir Ath-Thabari, maksud dari kalimat tersebut adalah janganlah kalian membunuh diri kalian dan sebagian dari kalian, padahal kalian dalam satu aliran, satu dakwah, dan satu agama. Allah menjadikan Islam sebagai agama yang saling bersaudara antar umatnya dan menjadikan orang yang membunuh di antara mereka seperti membunuh dirinya dan kasih sayang Allah senantiasa untuk hamba-Nya (Ahmad Abdurraziq Al Bakri).

Ayat ini menjelaskan bahwa Allah melarang untuk membunuh diri sendiri maupun orang lain karena Allah Maha Penyayang terhadap hambanya, sehingga kita harus mengingat akan kasih sayang-Nya. Ayat tersebut menjelaskan adanya *Muamalah ma'a Allah* atau hubungan dengan Allah yang terdapat pada kalimat "*inna Allaha kaana bikum rahiima*" (sesungguhnya Allah Maha Penyayang kepadamu) menunjukkan bahwa bunuh diri bukanlah solusi, karena Allah senantiasa memberi rahmat, kasih sayang, dan jalan keluar bagi hamba-Nya bahkan di tengah kesulitan yang paling berat sekalipun. Maka, perbuatan bunuh diri dianggap sebagai bentuk keputusan terhadap rahmat Allah, yang dalam Islam merupakan dosa besar dan Allah mengharamkan hal tersebut (Firmansyah, 2022). Seharusnya kita senantiasa mengingat akan rahmat Allah yang diberikan kepada hamba-Nya. Setiap Muslim seharusnya senantiasa mengingat dan meyakini bahwa rahmat Allah selalu dekat dan tersedia bagi siapa pun yang bersabar dan berdoa.

Dalam konteks *muamalah ma'a Allah*, ayat ini mengajarkan bahwa menjaga diri dan tetap berharap kepada Allah merupakan wujud keyakinan dan ketaatan, sekaligus cara untuk membangun hubungan spiritual yang sehat dan penuh keimanan.

Dari sudut pandang psikologi, bunuh diri sering kali merupakan akibat dari tekanan mental yang berat, seperti depresi berat, gangguan bipolar, atau trauma mendalam. Dalam hal ini, ayat di atas menunjukkan bahwa agama Islam sangat peduli terhadap kondisi mental manusia, dan mencegah tindakan yang merusak diri dengan cara memberikan peringatan dan penguatan spiritual. Dalam klasifikasi kesehatan mental, indikator seperti *suicidal thoughts* (pikiran untuk bunuh diri) adalah salah satu fitur krusial yang harus diperhatikan. Ayat ini dapat dijadikan dasar bahwa dalam konteks keislaman, deteksi dini dan pencegahan bunuh diri adalah bagian dari menjaga amanah kehidupan yang diberikan Allah.

Dalam konteks penelitian ini, pemahaman tersebut menjadi dasar untuk mengembangkan sistem klasifikasi kondisi psikologis berdasarkan data kuisioner yang diisi oleh para santri. Gejala-gejala seperti kelelahan mental, perubahan emosi, atau perasaan sedih berkepanjangan dapat dimodelkan sebagai variabel dalam klasifikasi menggunakan algoritma *machine learning Random Forest*.

*Random Forest* bekerja dengan membentuk banyak pohon keputusan (decision trees), kemudian menggabungkan hasil dari semua pohon tersebut untuk menghasilkan prediksi yang lebih akurat. Diharapkan sistem dapat mengidentifikasi kesehatan mental seseorang secara dini, dan memberikan

rekomendasi yang sesuai, baik dalam bentuk bimbingan spiritual maupun psikologis

## **BAB V**

### **KESIMPULAN DAN SARAN**

#### **4.9 Kesimpulan**

Berdasarkan penelitian yang dilakukan terhadap klasifikasi kesehatan mental santri Pondok Pesantren Al-Hikmah Al-Fathimiyyah menggunakan algoritma *Random Forest* dengan dan tanpa penerapan teknik SMOTE (*Synthetic Minority Over-sampling Technique*), diperoleh beberapa kesimpulan sebagai berikut:

1. Model *Random Forest* yang dikombinasikan dengan teknik SMOTE menghasilkan akurasi sebesar 90%. Nilai f1-score untuk kelas mayoritas dan minoritas masing-masing sebesar 0.94 dan 0.75. Macro average f1-score tercatat sebesar 0.85, yang menunjukkan bahwa performa model relatif merata antar kelas. Hal ini mencerminkan bahwa model dapat mengenali kedua kelas dengan distribusi performa yang seimbang.
2. Model *Random Forest* tanpa penerapan SMOTE menghasilkan akurasi sebesar 90%. Nilai f1-score untuk kelas mayoritas tercatat sebesar 0.94, sedangkan untuk kelas minoritas sebesar 0.80. Recall pada kelas minoritas mencapai 1.00, sementara precision sebesar 0.67, yang menunjukkan bahwa seluruh sampel kelas minoritas berhasil dikenali oleh model, namun terdapat sejumlah prediksi positif yang tidak sesuai. Perbedaan nilai antara precision dan recall pada kelas minoritas menunjukkan adanya ketidakseimbangan kinerja model dalam mengklasifikasikan kelas tersebut.

Kedua pendekatan menunjukkan akurasi yang sama, namun dengan karakteristik performa yang berbeda antar kelas. Ketidakseimbangan kinerja model dalam klasifikasi, terutama pada precision dan recall antar kelas, dapat menyebabkan hasil prediksi yang tidak konsisten dan berdampak langsung terhadap keakuratan penilaian serta keputusan intervensi. Oleh karena itu, penting untuk tidak hanya mempertimbangkan akurasi keseluruhan, tetapi juga mengevaluasi keseimbangan antar metrik pada masing-masing kelas. Pilihan penggunaan SMOTE atau tidak dapat disesuaikan dengan kebutuhan analisis, khususnya jika mempertimbangkan distribusi data dan prioritas terhadap keseimbangan antar kelas.

#### **4.10 Saran**

Dalam pengembangan system klasifikasi kesehatan mental menggunakan Random Forest, perlu adanya beberapa perbaikan untuk mencapai hasil yang optimal. Oleh karena itu, peneliti memberikan saran sebagai berikut:

1. Penelitian ini memiliki keterbatasan pada jumlah data yang relatif kecil, yaitu hanya 105 responden, yang dapat memengaruhi generalisasi model ke populasi yang lebih luas. Oleh karena itu, pada penelitian selanjutnya disarankan untuk memperluas cakupan data dengan melibatkan lebih banyak responden dari berbagai latar belakang dan institusi pendidikan, agar model yang dibangun menjadi lebih representatif dan akurat.
2. Klasifikasi dalam penelitian ini hanya terbatas pada dua kelas, yaitu normal dan depresi. Peneliti selanjutnya dapat mengembangkan klasifikasi dengan label yang lebih beragam, seperti bipolar tipe I, bipolar tipe II dan gunakan variabel-

variabel yang tepat, sehingga diagnosis yang dihasilkan lebih mendalam dan mendekati kondisi psikologis nyata.

## DAFTAR PUSTAKA

- Abdoh, S. F., Abo Rizka, M., & Maghraby, F. A. (2018). Cervical cancer diagnosis using random forest classifier with SMOTE and feature reduction techniques. *IEEE Access*, 6, 59475–59485. <https://doi.org/10.1109/ACCESS.2018.2874063>
- Aluh, D. O., Abba, A., & Afosi, A. B. (2020). Prevalence and correlates of depression, anxiety and stress among undergraduate pharmacy students in Nigeria. *Pharmacy Education*, 20, 236–248. <https://doi.org/10.46542/pe.2020.201.236248>
- Cahya, D., Buani, P., Rahmawati, A., Informatika, P. S., Mandiri, U. N., Studi, P., Informasi, S., Mandiri, U. N., & Forest, R. (2024). *KLASIFIKASI MENTAL DISORDER DENGAN MENGGUNAKAN*. 9(2), 101–109.
- Dianovinina, K. (2018). Depresi pada Remaja: Gejala dan Permasalahannya. *Journal Psikogenesis*, 6(1), 69–78. <https://doi.org/10.24854/jps.v6i1.634>
- Erdiansyah, U., Irmansyah Lubis, A., & Erwansyah, K. (2022). Komparasi Metode K-Nearest Neighbor dan Random Forest Dalam Prediksi Akurasi Klasifikasi Pengobatan Penyakit Kutil. *Jurnal Media Informatika Budidarma*, 6(1), 208. <https://doi.org/10.30865/mib.v6i1.3373>
- Firmansyah, I. R. (2022). *Suicidal Thought Dalam Al Quran (Studi Analisis Penafsiran Surah An-Nisa Ayat 29-30 Perspektif Tafsir Maqasidi)*. 86.
- Jindal, H., Agrawal, S., Khera, R., Jain, R., & Nagrath, P. (2021). Heart disease prediction using machine learning algorithms. *IOP Conference Series: Materials Science and Engineering*, 1022(1). <https://doi.org/10.1088/1757-899X/1022/1/012072>
- Kumar, V., & Kumar, A. (2020). Classification of Comparison-Based Analysis Between Rattle and Weka Tool on the Mental Health Disorder Problem Dataset Using Random Forest Tree Classifier. In *Lecture Notes in Networks and Systems* (Vol. 121, Issue Ic4s). Springer Singapore. [https://doi.org/10.1007/978-981-15-3369-3\\_47](https://doi.org/10.1007/978-981-15-3369-3_47)
- Kurniasari, E., Rusmana, N., & Budiman, N. (2019). Gambaran Umum Kesejahteraan Psikologis Mahasiswa Universitas Pendidikan Indonesia. *Journal of Innovative Counseling : Theory, Practice & Research*, 3(2), 52–58.
- Kusumarini, A. I., Hogantara, P. A., Fadhlurohman, M., & Nurul Chamidah, S. K. . M. K. (2021). Perbandingan Algoritma Random Forest, Naive Bayes, Dan Decision Tree Dengan Oversampling Untuk Klasifikasi Bakteri E.Coli. *Prosiding Seminar Nasional Mahasiswa Bidang Ilmu Komputer Dan Aplikasinya*, 2(1), 792–799.
- Maramis M Margarita. (2022). *Gangguan Bipolar dan Psikoedukasi*.

- Maringka, R., & Kusnawi, K. (2021). Exploratory Data Analysis Faktor Pengaruh Kesehatan Mental di Tempat Kerja. *CogITo Smart Journal*, 7(2), 215–226. <https://doi.org/10.31154/cogito.v7i2.312.215-226>
- Marsuhandi, A. H., Soleh, A. M., Wijayanto, H., & Domiri, D. D. (2020). Pemanfaatan Ensemble Learning Dan Penginderaan Jauh Untuk Pengklasifikasian Jenis Lahan Padi. *Seminar Nasional Official Statistics*, 2019(1), 188–195. <https://doi.org/10.34123/semnasoffstat.v2019i1.247>
- Maulana, M. I., Lessy, Z., Islam, U., Sunan, N., Islam, U., & Sunan, N. (2023). Upaya Penanganan Dan Peningkatan Kesehatan Mental. *Koloni*, 2(4), 90–98.
- Mohammed, A. J. (2020). Improving Classification Performance for a Novel Imbalanced Medical Dataset using SMOTE Method. *International Journal of Advanced Trends in Computer Science and Engineering*, 9(3), 3161–3172. <https://doi.org/10.30534/ijatcse/2020/104932020>
- Mohd Shafiee, N. S., & Mutalib, S. (2020). Prediction of Mental Health Problems among Higher Education Student Using Machine Learning. *International Journal of Education and Management Engineering*, 10(6), 1–9. <https://doi.org/10.5815/ijeme.2020.06.01>
- Mourya, S., Srinivas, P. V. S., & Seetha, M. (2018). Multi-attributes web objects classification based on class-attribute relation patterns learning approach. *International Journal of Advanced Computer Science and Applications*, 9(12), 409–416. <https://doi.org/10.14569/IJACSA.2018.091258>
- Nurasih, W., Amalia, F. R., Muthohar, A., Mada, U. G., Islam, U., Prof, N., Syaifuddin, K. H., Islam, U., Prof, N., & Syaifuddin, K. H. (2023). LIVING QUR ' AN DI RUMAH SAKIT ISLAM PURWOKERTO ( Implementasi Surat Asy-Syu ' ara Ayat 80 dalam Pelayanan Divisi Bimbingan Rohani Islam ) Pendahuluan Al-Qur ' an sebagai kitab suci umat muslim sebagai pedoman utama dalam. *Jurnal Studi Al-Qur'an Dan Tafsir*, 01 (01), 29–44.
- Nurdiansyah, N., Febriyan, F. S., Gesit, Z., & Amanta, D. (2025). *Mental Health Analysis to Prevent Mental Disorders in Students Using The K-Nearest Neighbor ( K-NN ) Algorithm and Random Forest Algorithm Analisis Kesehatan Mental untuk Mencegah Gangguan Mental pada Mahasiswa Menggunakan Algoritma K-Nearest Neighbor ( K. 5(January), 1–9.*
- Oktaviani, V., Rosmawarni, N., & Muslim, M. P. (2024). Perbandingan Kinerja Random Forest Dan Smote Random Forest Dalam Mendeteksi Dan Mengukur Tingkat Stres Pada Mahasiswa Tingkat Akhir. *Informatik : Jurnal Ilmu Komputer*, 20(1), 43–49. <https://doi.org/10.52958/iftk.v20i1.9158>
- Pritam, N., Gill, K. S., Kumar, M., Rawat, R., & Banerjee, D. (2024). Classification of Student Mental Health Analysis using Logistic Regression and other classification techniques through Machine Learning Methods. *2024 3rd International Conference for Innovation in Technology, INOCON 2024*, 1–5. <https://doi.org/10.1109/INOCON60754.2024.10512216>

- Priyono, A., Shodiq, M., Alvinsyah, D. P., & Hidayah, S. A. (2024). Metode Random Forest Untuk Memudahkan Klasifikasi Diagnosis Penyakit Mental. *Jurnal Informatika Medis (J-INFORMED)*, 2(1), 1–4. <https://doi.org/10.52060/im.v2i1.2119>
- Psikologis Remaja Akibat Kurangnya Perhatian Orangtua di Desa Balekencono Ita Wulandari, K., & Tohir, M. (2019). Bulletin of Counseling and Psychotherapy. *Bulletin of Counseling and Psychotherapy*, 1(1), 53.
- Radhika, R., & Thomas George, S. (2021). Heart Disease Classification Using Machine Learning Techniques. *Journal of Physics: Conference Series*, 1937(1). <https://doi.org/10.1088/1742-6596/1937/1/012047>
- Ramadhon, R. N., Ogi, A., Agung, A. P., Putra, R., Febrihartina, S. S., & Firdaus, U. (2024). Implementasi Algoritma Decision Tree untuk Klasifikasi Pelanggan Aktif atau Tidak Aktif pada Data Bank. *Karimah Tauhid*, 3(2), 1860–1874. <https://doi.org/10.30997/karimahtauhid.v3i2.11952>
- Sabani, R. F. A. (2022). Analisis Hadis Lā Dharara Walā Dhirāran sebagai Dasar Fatwa Keharaman Rokok. *Jurnal Penelitian Ilmu Ushuluddin*, 2(2), 268–293. <https://doi.org/10.15575/jpiu.v2i2.13693>
- Santrock, J. W. (2019). *Adolescence / John W. Santrock, University of Texas at Dallas*.
- Sebayang, E. R. B., Chrisnanto, Y. H., & Melina. (2023). Klasifikasi Data Kesehatan Mental di Industri Teknologi Menggunakan Algoritma Random Forest. *IJESPG Journal*, 1(3), 237–253.
- Selection, F., Yogyakarta, U. A., & Yogyakarta, U. A. (n.d.). *Classification of mental disorders using modified balanced random forest and feature selection*. 45–54.
- Steen, J. (2021). *Peter Anto Johnson Simran Bakshi Anthony Chen John Christy Johnson Rahma Gulaid Avery Kennedy Asfar Khan Austin Mardon Arnavi Patel Nasia Sheikh April Sui Jeremy Steen* (Issue October).
- Stevani, H., Riska Andriani, & Fijriani, F. (2019). Analisis Kondisi Psikologis Siswa Serta Implikasinya Terhadap Program Bimbingan Dan Konseling. *ENLIGHTEN (Jurnal Bimbingan Dan Konseling Islam)*, 2(2), 62–67. <https://doi.org/10.32505/enlighten.v2i2.1343>
- Suci Amaliah, Nusrang, M., & Aswi, A. (2022). Penerapan Metode Random Forest Untuk Klasifikasi Varian Minuman Kopi di Kedai Kopi Konijiwa Bantaeng. *VARIANSI: Journal of Statistics and Its Application on Teaching and Research*, 4(3), 121–127. <https://doi.org/10.35580/variansiunm31>
- Sumathi, M., & B., D. (2016). Prediction of Mental Health Problems Among Children Using Machine Learning Techniques. *International Journal of Advanced Computer Science and Applications*, 7(1), 552–557. <https://doi.org/10.14569/ijacsa.2016.070176>

- Sun, Y. (2024). Mental Health Classification and Diagnosis System Based on Random Forest Algorithm. *2nd IEEE International Conference on Data Science and Information System, ICDSIS 2024*, 1–6. <https://doi.org/10.1109/ICDSIS61070.2024.10594527>
- Tamba, S. P., & -, E. (2022). Prediksi Penyakit Gagal Jantung Dengan Menggunakan Random Forest. *Jurnal Sistem Informasi Dan Ilmu Komputer Prima(JUSIKOM PRIMA)*, 5(2), 176–181. <https://doi.org/10.34012/jurnalsisteminformasidanilmukomputer.v5i2.2445>
- Wajhillah, R., Bahri, S., & Wibowo, A. (2020). Komparasi Metode Machine Learning pada Diagnosa Gangguan Kejiwaan Depresi. *Syntax : Jurnal Informatika*, 9(1), 26–31. <https://doi.org/10.35706/syji.v9i1.2050>