

BAB I

PENDAHULUAN

1.1 Latar Belakang

Kesehatan Mental merupakan salah satu aspek fundamental dalam kesejahteraan individu yang memengaruhi kemampuan seseorang dalam berpikir, mengelola emosi, dan berperilaku secara adaptif dalam kehidupan sehari-hari. Gangguan mental didefinisikan sebagai kondisi yang ditandai oleh adanya gangguan signifikan pada kognisi, regulasi emosi, atau perilaku yang mencerminkan disfungsi dalam proses psikologis, biologis, maupun perkembangan individu (American Psychiatric Association, 2013). Gangguan mental telah menjadi isu kesehatan masyarakat global yang terus meningkat dalam dua dekade terakhir, serta memberikan kontribusi besar terhadap beban penyakit dunia. *World Health Organization* (WHO) melaporkan bahwa lebih dari satu miliar penduduk dunia hidup dengan gangguan mental, dengan gangguan kecemasan dan depresi sebagai jenis yang paling umum terjadi (WHO, 2025). Gangguan mental tidak hanya berdampak pada kualitas hidup individu, tetapi juga meningkatkan angka disabilitas dan beban ekonomi akibat hilangnya produktivitas kerja. Kondisi ini menjadikan kesehatan mental sebagai salah satu prioritas utama dalam agenda kesehatan global.

Hasil Riset Kesehatan Dasar (Riskesdas) tahun 2018 mencerminkan urgensi penanganan kesehatan mental di Indonesia. Riset tersebut menunjukkan bahwa sekitar 19 juta penduduk usia di atas 15 tahun mengalami gangguan emosional dan prevalensi gangguan jiwa berat mengalami peningkatan dibandingkan periode sebelumnya (Kementerian Kesehatan RI, 2018). Data tersebut menunjukkan bahwa gangguan

mental bukan lagi permasalahan individual, melainkan telah menjadi tantangan kesehatan masyarakat yang memerlukan pendekatan komprehensif dan sistematis. Penegakan diagnosis gangguan mental dalam praktik klinis dilakukan berdasarkan pedoman standar seperti Pedoman Penggolongan dan Diagnosis Gangguan Jiwa III (PPDGJ-III), yang mengklasifikasikan gangguan berdasarkan kumpulan gejala yang teridentifikasi (Maslim, 2013). Proses diagnosis sering kali menghadapi tantangan karena gejala yang muncul dapat bersifat tumpang tindih antar gangguan, bervariasi antar individu, serta memerlukan analisis rekam medis yang kompleks. Kompleksitas ini membuka peluang pemanfaatan pendekatan berbasis data untuk mendukung proses identifikasi dan klasifikasi gangguan mental secara lebih sistematis.

Gangguan mental jarang muncul sebagai kondisi tunggal pada praktik klinis. Banyak pasien menunjukkan lebih dari satu diagnosis secara bersamaan, yakni sebuah fenomena yang dikenal sebagai komorbiditas. Komorbiditas pada gangguan mental merupakan kondisi umum, khususnya antara gangguan kecemasan, depresi, dan gangguan suasana hati lainnya (Kessler et al., 2005). Tumpang tindih gejala antar gangguan menyebabkan proses identifikasi menjadi semakin kompleks, karena satu gejala dapat berkontribusi terhadap lebih dari satu kategori diagnosis. Sistem klasifikasi seperti DSM-5 maupun PPDGJ-III menetapkan diagnosis berdasarkan kombinasi sejumlah kriteria gejala tertentu yang harus terpenuhi dalam periode waktu tertentu (American Psychiatric Association, 2013; Maslim, 2013). Pola ini menunjukkan bahwa hubungan antara gejala dan diagnosis bersifat banyak-ke-banyak (*many-to-many*), di mana satu kumpulan gejala dapat mengarah pada beberapa kemungkinan gangguan, dan satu gangguan dapat ditandai oleh berbagai kombinasi

gejala. Kompleksitas inilah yang menjadikan proses diagnosis tidak hanya membutuhkan ketelitian klinis, tetapi juga analisis pola data yang sistematis.

Karakteristik tersebut sejalan dengan permasalahan klasifikasi multilabel dalam konteks pengolahan data, yakni suatu keadaan yang memungkinkan satu objek memiliki lebih dari satu label secara bersamaan (Tsoumakas & Katakis, 2007). Berbeda dengan klasifikasi tradisional yang hanya memprediksi satu kelas untuk setiap objek, pendekatan multilabel memungkinkan representasi yang lebih realistis terhadap kasus-kasus komorbiditas pada gangguan mental. Oleh karena itu, penerapan metode klasifikasi multilabel menjadi relevan untuk mendukung proses identifikasi diagnosis berbasis data kesehatan. Klasifikasi ini telah banyak dimanfaatkan dalam ranah medis yang melibatkan lebih dari satu diagnosis guna meningkatkan ketepatan identifikasi penyakit komorbid pada pasien (Wosiak et al., 2018). Efektivitas klasifikasi multilabel juga telah dibuktikan pada penelitian terkait kasus kesehatan jiwa di Nigeria (Folorunso et al., 2020).

Penerapan metode klasifikasi berbasis machine learning pada data kesehatan mental umumnya merepresentasikan setiap pasien melalui sejumlah besar atribut atau fitur, seperti daftar gejala, riwayat medis, faktor demografis, serta hasil asesmen psikologis. Tidak semua fitur tersebut memiliki kontribusi yang sama terhadap proses penentuan diagnosis. Beberapa fitur mungkin sangat relevan terhadap satu gangguan tertentu, namun kurang informatif terhadap gangguan lainnya. Kondisi ini menjadi semakin kompleks dalam skenario multilabel, karena satu fitur dapat memiliki tingkat relevansi yang berbeda terhadap masing-masing label. Keberadaan fitur yang tidak relevan atau redundan dapat menurunkan performa model klasifikasi, meningkatkan kompleksitas komputasi, serta berpotensi menyebabkan *overfitting* (Guyon &

Elisseeff, 2003). Oleh karena itu, proses seleksi fitur menjadi tahap penting dalam membangun model klasifikasi yang efisien dan akurat. Pada permasalahan multilabel, pendekatan seleksi fitur konvensional yang dirancang untuk *single-label* sering kali kurang optimal karena tidak mempertimbangkan korelasi antar label maupun relevansi fitur terhadap lebih dari satu label secara simultan.

Beberapa penelitian menunjukkan bahwa metode seleksi fitur berbasis *Mutual Information* efektif dalam mengukur tingkat ketergantungan antara fitur dan label (Peng, Long, & Ding, 2005). Pendekatan tersebut umumnya hanya menilai relevansi secara individual dan belum sepenuhnya mempertimbangkan struktur multilabel. Pendekatan *Multilabel Feature Selection* (MFS) kemudian dikembangkan guna mengatasi masalah tersebut karena kemampuannya dalam mengintegrasikan informasi relevansi global dan hubungan antar objek di ruang fitur dan label (Spolaôr et al., 2013).

Salah satu metode seleksi fitur multilabel yang dikembangkan untuk mengatasi permasalahan relevansi dan redundansi secara simultan adalah *Multilabel Feature Selection Using Mutual Information and ML-Relief* (MFS-MIRF) yang diusulkan oleh Shi et al. (2020). Metode ini menggabungkan pendekatan filter berbasis Mutual Information dengan algoritma *ML-Relief* dalam dua tahap seleksi. Tahap pertama menggunakan *Weighted Mutual Information* (WMI) untuk menyaring fitur berdasarkan tingkat relevansi global terhadap distribusi label multilabel. Selanjutnya, tahap kedua menggunakan *ML-Relief* untuk mengevaluasi kontribusi fitur berdasarkan kedekatan antar objek dengan mempertimbangkan kesamaan fitur dan label. Pendekatan dua tahap ini dirancang untuk menghasilkan subset fitur yang tidak hanya relevan terhadap label, tetapi juga mampu meminimalkan redundansi antar fitur.

Penerapan metode seleksi fitur multilabel menjadi krusial dalam konteks diagnosis gangguan mental, mengingat kompleksitas hubungan antara gejala dan berbagai kemungkinan gangguan yang dapat muncul secara bersamaan. Seleksi fitur yang tepat diharapkan mampu meningkatkan performa klasifikasi sekaligus mengurangi kompleksitas model yang dibangun.

Berbagai metode seleksi fitur multilabel telah dikembangkan, termasuk MFS-MIRF yang diusulkan oleh Shi et al. (2020), namun sebagian besar penelitian masih berfokus pada dataset umum seperti teks dan citra. Penerapan metode tersebut pada konteks diagnosis gangguan mental, khususnya pada data kategorikal yang merepresentasikan gejala klinis pasien, masih relatif terbatas. Karakteristik diagnosis gangguan mental yang memungkinkan terjadinya komorbiditas menjadikan pendekatan multilabel sangat relevan untuk digunakan. Integrasi metode seleksi fitur multilabel dengan algoritma klasifikasi yang sederhana dan efisien seperti *Naive Bayes* belum banyak dieksplorasi dalam domain kesehatan mental. Hal ini menjadi krusial mengingat efisiensi komputasi dan interpretabilitas model merupakan pertimbangan penting dalam ranah tersebut.

Beberapa penelitian telah mengkaji penggunaan *Naive Bayes* dalam konteks multilabel. Zhang, Peña, dan Robles (2009) memperkenalkan adaptasi *Multilabel Naive Bayes* serta mengevaluasi strategi seleksi fitur untuk meningkatkan performa klasifikasi. Chitra et al. (2024) mengembangkan model MLNB dengan mempertimbangkan ketergantungan antar label melalui perluasan ruang fitur, sehingga model tidak sepenuhnya bergantung pada asumsi independensi label. Prawira et al. (2018) juga menerapkan *Multinomial Naive Bayes* pada klasifikasi multilabel dalam domain teks dan menunjukkan potensinya sebagai model baseline. Kombinasi antara

metode seleksi fitur multilabel MFS-MIRF dan algoritma *Multilabel Naive Bayes* pada konteks diagnosis gangguan mental sejauh ini belum banyak dilaporkan dalam literatur.

Penelitian ini menerapkan pendekatan klasifikasi *multilabel* menggunakan strategi *Binary Relevance* yang mengadaptasi algoritma *Naive Bayes* untuk setiap label secara independen. *Naive Bayes* dipilih karena kesederhanaan model, efisiensi komputasi, serta kemampuannya dalam menangani data kategorikal (Zhang, 2004). Algoritma ini tetap menunjukkan performa yang kompetitif pada berbagai permasalahan klasifikasi sekalipun mengasumsikan independensi antar fitur. Penelitian ini bertujuan untuk mengevaluasi efektivitas kombinasi metode seleksi fitur MFS-MIRF dan *Multilabel Naive Bayes* dalam meningkatkan performa klasifikasi diagnosis gangguan mental berbasis *multilabel*.

Berdasarkan permasalahan yang telah diuraikan, penelitian ini bertujuan untuk menerapkan metode *Multilabel Feature Selection Using Mutual Information and ML-ReliefF (MFS-MIRF)* dalam proses seleksi fitur pada data diagnosis gangguan mental serta mengintegrasikannya dengan algoritma *Multilabel Naive Bayes* menggunakan pendekatan *Binary Relevance*. Penelitian ini memfokuskan pada empat label diagnosis, yaitu Skizofrenia, Gangguan Skizoafektif, Gangguan Bipolar, dan Episode Depresi, yang memiliki potensi komorbiditas serta kemiripan gejala klinis sehingga menimbulkan kompleksitas dalam proses penegakan diagnosis. Dataset yang digunakan terdiri atas 25 fitur gejala klinis yang disesuaikan dengan ketersediaan data rekam medis pasien di RSUD dr. Loekmono Hadi Kudus. Penelitian ini bertujuan menganalisis pengaruh seleksi fitur pada model *Multilabel Naive Bayes* terhadap performa klasifikasi serta mengevaluasi efektivitasnya menggunakan metrik *Hamming*

loss. Hasil penelitian ini diharapkan dapat memberikan kontribusi empiris dalam pengembangan metode klasifikasi *multilabel* yang efisien dan akurat untuk mendukung proses identifikasi diagnosis gangguan mental berbasis data.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah disampaikan sebelumnya, maka rumusan masalah dalam penelitian ini dapat diuraikan sebagai berikut:

1. Bagaimana penerapan algoritma *Multilabel Naive Bayes* dengan seleksi fitur menggunakan MFS-MIRF dalam mengklasifikasikan data diagnosis gangguan mental?
2. Bagaimana jumlah subset fitur paling optimal yang dihasilkan oleh algoritma seleksi fitur MFS-MIRF untuk mencapai kinerja klasifikasi terbaik pada model *Multilabel Naive Bayes* dengan pendekatan *Binary Relevance*?
3. Bagaimana perbandingan evaluasi performa model *Multilabel Naive Bayes* dengan pendekatan *Binary Relevance* antara model tanpa seleksi fitur (*baseline model*) dengan model yang menggunakan seleksi fitur MFS-MIRF?

1.3 Batasan Masalah

Penelitian ini memiliki beberapa batasan agar ruang lingkupnya lebih terarah dan tidak menyimpang dari tujuan yang telah ditetapkan, batasan masalah tersebut adalah sebagai berikut:

1. Variabel prediktor pada penelitian ini dibatasi pada 25 gejala klinis utama yang tercatat selama masa pemeriksaan atau perawatan pasien, yang disesuaikan dengan ketersediaan kelengkapan data rekam medis di RSUD dr. Loekmono Hadi Kudus.

2. Pada tahap penyaringan awal di dalam algoritma MFS-MIRF, parameter ambang batas (*top-N filter*) ditetapkan secara statis sebesar 70% dari total fitur gejala klinis. Penetapan nilai ini didasarkan pada hasil pengujian empiris awal pada dataset kesehatan mental yang digunakan. Dari beberapa variasi persentase yang diuji, pemotongan di angka 70% terbukti memberikan performa klasifikasi yang paling optimal. Titik ambang batas ini secara efektif membuang 30% fitur (*noise*) berskor rendah untuk meringankan evaluasi algoritma *ML-ReliefF*, namun tetap mempertahankan mayoritas fitur krusial yang paling relevan terhadap label diagnosis..
3. Pengaturan *hyperparameter* pada algoritma evaluasi jarak *ML-ReliefF* di dalam metode MFS-MIRF ditetapkan secara statis (manual), yaitu jumlah sampel iterasi (m) sebesar 214, jumlah tetangga terdekat (k) sebesar 5, dan nilai parameter δ sebesar 0,5, tanpa menerapkan proses *hyperparameter tuning* otomatis.
4. Pengujian untuk mencari jumlah subset fitur optimal (N) dibatasi pada skenario pemotongan fitur secara bertahap berdasarkan peringkat bobot tertinggi hasil evaluasi MFS-MIRF, hingga batas maksimal sesuai hasil penyaringan awal fitur (*top – 70%*).
5. Penelitian ini tidak mencakup proses penanganan ketidakseimbangan distribusi kelas data (*class imbalance*), sehingga evaluasi kinerja murni difokuskan pada pengaruh seleksi fitur MFS-MIRF terhadap algoritma MLNB pada kondisi data medis asli.

1.4 Tujuan Penelitian

Berdasarkan latar belakang dan rumusan masalah yang telah diuraikan, penelitian ini memiliki tujuan sebagai berikut:

1. Menerapkan algoritma *Multilabel Naive Bayes* dengan seleksi fitur menggunakan algoritma MFS-MIRF untuk mengklasifikasikan diagnosis pasien gangguan mental di RSUD dr. Loekmono Hadi Kudus.
2. Menentukan jumlah subset fitur paling optimal yang dihasilkan oleh algoritma seleksi fitur MFS-MIRF untuk mencapai kinerja klasifikasi terbaik pada model *Multilabel Naive Bayes* dengan pendekatan *Binary Relevance*.
3. Menganalisis perbandingan evaluasi performa model *Multilabel Naive Bayes* dengan pendekatan *Binary Relevance* antara model tanpa seleksi fitur (*baseline model*) dengan model yang menggunakan seleksi fitur MFS-MIRF dalam melakukan klasifikasi diagnosis gangguan mental.