

## **Analisis Dan Deteksi Burnout Pada Kalangan Anak Muda Dengan Algoritma Naïve Bayes**

**Agustina Simangunsong<sup>1</sup>, R. Mahdalena Simanjourang<sup>2</sup>, Penda Sudarto Hasugian<sup>3</sup>, Fitri Amalia<sup>4</sup>, Putri Khairunnisa<sup>5</sup>**

<sup>1,4,5</sup> Teknik Informatika, STMIK Pelita Nusantara

<sup>2</sup> Teknologi Informasi, STMIK Pelita Nusantara

<sup>3</sup> Bisnis Digital, STMIK Pelita Nusantara

Email: <sup>1,\*</sup> agustinasimangunsong93@gmail.com, <sup>2</sup> lenasinaga30@gmail.com, <sup>3</sup> penda.hasugian@gmail.com,

<sup>4</sup> fitriamalia9935@gmail.com, <sup>5</sup> khairunnisa\_putriiii@gmail.com

Email Penulis Korespondensi: agustinasimangunsong93@gmail.com

### **Abstrak**

Burnout pada anak muda menjadi fenomena yang semakin mengkhawatirkan seiring meningkatnya tekanan akademik, tuntutan pekerjaan, serta intensitas aktivitas digital di era modern. Kondisi ini ditandai oleh kelelahan emosional, depersonalisasi, dan menurunnya pencapaian pribadi yang berdampak langsung pada kesehatan mental dan performa individu. Penelitian ini bertujuan untuk menganalisis tingkat burnout pada kalangan anak muda serta membangun model deteksi otomatis menggunakan algoritma Naïve Bayes. Sebanyak 200 responden berusia 18–30 tahun dilibatkan melalui kuesioner daring berbasis skala Likert, dengan lima variabel utama yaitu Emotional Exhaustion (EE), Depersonalization (DP), Personal Accomplishment (PA), Stres Akademik/Pekerjaan (SA), dan Kualitas Tidur (QT). Proses analisis dilakukan melalui tahapan KDD yang meliputi data cleaning, transformation, data mining, dan evaluation menggunakan metode klasifikasi Naïve Bayes. Hasil penelitian menunjukkan bahwa 55% responden berada pada kategori burnout. Variabel QT Buruk, SA Tinggi, EE Tinggi, DP Tinggi, dan PA Rendah memiliki pengaruh paling signifikan terhadap terbentuknya burnout. Nilai likelihood kelas burnout sebesar 0,08305, jauh lebih tinggi dibandingkan kelas tidak burnout sebesar 0,0000733, sehingga kasus uji diklasifikasikan sebagai burnout. Temuan ini menunjukkan bahwa algoritma Naïve Bayes efektif digunakan sebagai alat deteksi dini burnout pada anak muda serta berpotensi mendukung pengembangan sistem monitoring kesehatan mental.

**Kata Kunci:** Burnout, Naïve Bayes, Data Mining, Kesehatan Mental, Klasifikasi

### **Abstract**

Burnout among young adults has emerged as a growing concern in the digital era, driven by increasing academic pressure, workplace demands, and high exposure to online activities. This condition is characterized by emotional exhaustion, depersonalization, and diminished personal accomplishment, which significantly affect mental well-being and individual performance. This study aims to analyze burnout levels among young adults and develop an automated detection model using the Naïve Bayes algorithm. A total of 200 respondents aged 20–30 years participated through an online Likert-scale questionnaire, covering five primary variables: Emotional Exhaustion (EE), Depersonalization (DP), Personal Accomplishment (PA), Academic/Work Stress (SA), and Sleep Quality (QT). The analysis followed the Knowledge Discovery in Database (KDD) stages, including data cleaning, transformation, data mining, and evaluation using Naïve Bayes classification. Results indicate that 55% of respondents fall into the burnout category. The most influential attributes in distinguishing burnout are Poor Sleep Quality, High Academic/Work Stress, High Emotional Exhaustion, High Depersonalization, and Low Personal Accomplishment. The likelihood value for the burnout class is 0.08305, significantly higher than 0.0000733 for the non-burnout class, indicating that the test case is classified as experiencing burnout. These findings demonstrate that the Naïve Bayes algorithm is effective as an early detection tool for identifying burnout among young adults and has potential to support the development of mental health monitoring systems.

**Keywords:** Burnout, Naïve Bayes, Data Mining, Mental Health, Classification

## **1. PENDAHULUAN**

Perkembangan teknologi yang pesat di era digital membawa dampak signifikan terhadap gaya hidup dan pola pikir anak muda. Kehadiran media sosial, sistem pembelajaran daring, dan mobilitas informasi yang tinggi menuntut generasi muda untuk selalu adaptif terhadap perubahan. Namun, di balik kemudahan tersebut, muncul tekanan baru berupa tuntutan produktivitas yang berlebihan dan ekspektasi sosial yang meningkat. Anak muda kini tidak hanya berlomba dalam pencapaian akademik, tetapi juga dalam menampilkan citra diri yang ideal di dunia maya. Kondisi ini seringkali menimbulkan stres berkepanjangan yang berujung pada burnout, terutama ketika tidak diimbangi dengan manajemen waktu dan emosi yang baik.

Fenomena burnout pada anak muda menjadi isu serius dalam masyarakat modern. Burnout merupakan kondisi kelelahan emosional, fisik, dan mental akibat paparan tekanan secara terus-menerus. Di tengah perkembangan teknologi, anak muda semakin sulit memisahkan kehidupan pribadi dengan aktivitas digitalnya. Mereka terjebak dalam rutinitas multitasking antara studi, pekerjaan, dan interaksi daring yang intens. Selain itu, algoritma media sosial yang mendorong konsumsi konten berlebihan sering kali memperburuk kondisi psikologis, menimbulkan kecemasan, dan menurunkan

fokus. Akumulasi tekanan tersebut secara perlahan mengarah pada kelelahan psikologis yang sulit diidentifikasi secara kasat mata.

Perubahan sosial dan teknologi juga menciptakan budaya baru yang dikenal sebagai *hustle culture*, yaitu pandangan bahwa kesuksesan hanya dapat diraih melalui kerja keras tanpa henti. Anak muda merasa harus selalu produktif untuk diakui, baik secara akademik maupun profesional. Sayangnya, ketika performa menurun, banyak dari mereka yang tidak menyadari sedang mengalami *burnout*. Berbagai studi menunjukkan peningkatan signifikan kasus stres dan gangguan psikologis pada usia 18–30 tahun akibat tekanan digital dan beban pekerjaan. Situasi ini menuntut pendekatan ilmiah yang mampu mendeteksi *burnout* secara objektif menggunakan data perilaku dan psikologis anak muda.

Seiring berkembangnya bidang *machine learning* dan *data mining*, analisis kesehatan mental kini dapat dilakukan secara otomatis melalui pendekatan komputasional. Salah satu algoritma yang banyak digunakan untuk klasifikasi data psikologis adalah *Naïve Bayes*. Metode ini memiliki keunggulan dalam kecepatan, kesederhanaan, dan efektivitas dalam mengolah data probabilistik. Dengan menggunakan algoritma ini, sistem dapat mendeteksi tingkat *burnout* berdasarkan parameter seperti durasi tidur, aktivitas fisik, tingkat stres, dan intensitas penggunaan media sosial. Hasil analisis ini dapat membantu peneliti dan praktisi memahami pola *burnout* dengan lebih akurat dan berbasis data empiris.

Integrasi teknologi dengan analisis psikologis memberikan peluang baru dalam pencegahan dan penanganan *burnout*. Melalui penerapan *Naïve Bayes*, penelitian ini berupaya membangun model klasifikasi yang mampu mendeteksi tingkat *burnout* pada kalangan anak muda secara otomatis. Proses pengolahan data dilakukan melalui tahapan *Knowledge Discovery in Database (KDD)* yang mencakup *data cleaning*, *data selection*, *transformation*, *data mining*, dan *evaluation*. Pendekatan ini tidak hanya menghasilkan model prediktif, tetapi juga dapat dijadikan dasar untuk pengembangan sistem pendukung keputusan di bidang kesehatan mental.

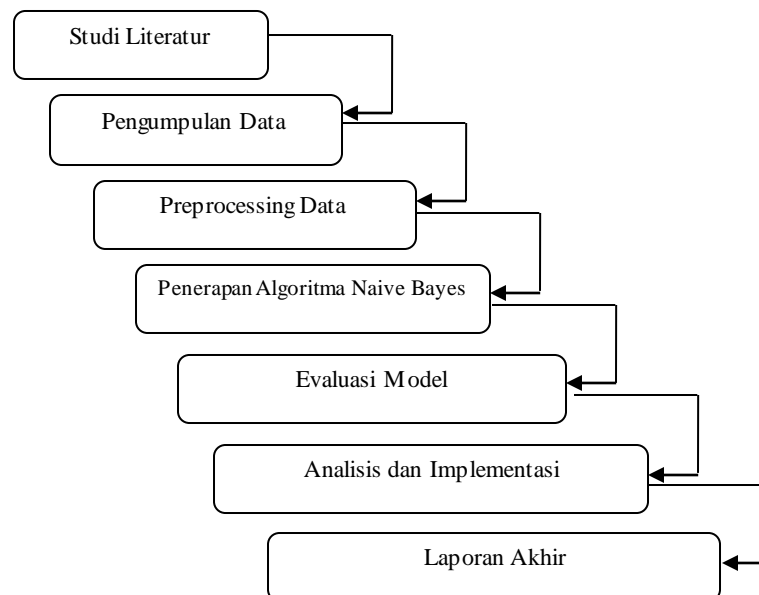
Penelitian ini memiliki relevansi tinggi di tengah perkembangan teknologi informasi yang semakin kompleks dan interaktif. Deteksi *burnout* berbasis algoritma *Naïve Bayes* diharapkan dapat membantu lembaga pendidikan, organisasi, maupun individu dalam mengenali tanda-tanda kelelahan psikologis sejak dini. Dengan menggabungkan aspek psikologis dan komputasional, penelitian ini menjadi kontribusi nyata bagi penerapan teknologi cerdas dalam meningkatkan kesejahteraan mental generasi muda. Selain itu, hasil penelitian ini dapat mendorong kesadaran *digital wellbeing* sebagai bagian penting dari literasi teknologi modern yang berkelanjutan.

Beberapa solusi sudah ditawarkan pada penelitian sebelumnya pada penelitian oleh *Using Machine Learning in Burnout Prediction* [1][2] : menyimpulkan bahwa *machine learning* menjadi pendekatan yang makin penting karena metode tradisional (misalnya kuesioner, wawancara) tidak cukup menangani volume data besar serta variabel multifaktorial dalam kondisi *burnout* modern. Dalam kerangka era digital, anak muda menghadapi tekanan tambahan: *multitasking* (belajar + kerja + sosial media), kebisingan informasi, kurang tidur, dan isolasi virtual. Kondisi ini meningkatkan risiko *burnout* yang tidak segera terdeteksi. Sejalan dengan itu, literatur juga menunjukkan bahwa teknologi *mobile* dan *wearable* dapat menghadirkan data *real-time* dari aktivitas harian, sehingga potensi deteksi dini *burnout* menjadi semakin besar. Selanjutnya pada penelitian oleh [3] berjudul “Implementasi Metode *Naïve Bayes* untuk Mendeteksi Stres Siswa Berdasarkan Tweet pada Sistem Monitoring Stres” menjadi salah satu rujukan penting dalam pengembangan sistem deteksi kesehatan mental berbasis *machine learning*. Studi tersebut menggunakan algoritma *Naïve Bayes* untuk mengklasifikasikan tingkat stres siswa berdasarkan analisis teks dari media sosial Twitter. Melalui proses *text mining* dan klasifikasi, model ini berhasil mengelompokkan tingkat stres ke dalam tiga kategori, yaitu stres ringan, sedang, dan berat, dengan tingkat akurasi mencapai 75%. Hasil ini membuktikan bahwa algoritma *Naïve Bayes* mampu menangani data teks dengan cepat, efisien, dan cukup akurat meskipun menggunakan jumlah data terbatas. Penelitian tersebut juga menunjukkan potensi penerapan analisis perilaku digital dalam mendeteksi kondisi psikologis individu, khususnya remaja dan pelajar yang aktif di media sosial. Berdasarkan temuan tersebut, penelitian ini mengadaptasi dan memperluas penerapan algoritma *Naïve Bayes* untuk mendeteksi *burnout* pada kalangan anak muda. Dan juga pada penelitian oleh [4] berjudul “Penerapan Algoritma *Naïve Bayes* dalam *Machine Learning* untuk Klasifikasi Faktor-Faktor yang Mempengaruhi Kesehatan Mental Siswa” menunjukkan kemajuan signifikan dalam pemanfaatan algoritma *Naïve Bayes* untuk menganalisis kondisi psikologis siswa. Penelitian ini menggunakan dataset yang mencakup informasi demografis, tekanan akademik, kepuasan belajar, durasi tidur, kebiasaan diet, serta riwayat kesehatan mental untuk memprediksi risiko depresi dan pikiran bunuh diri. Hasil klasifikasi menunjukkan bahwa faktor tekanan akademik dan pola makan memiliki pengaruh paling besar terhadap kondisi mental siswa. Model *Naïve Bayes* terbukti efisien dalam mengidentifikasi pola tersembunyi dari data kompleks, menghasilkan analisis cepat dengan akurasi yang memadai. Dalam konteks penelitian ini, temuan Supriani dkk. menjadi dasar empiris penting untuk mengembangkan sistem deteksi *burnout* pada kalangan anak muda. *Burnout* memiliki kemiripan karakteristik dengan depresi ringan dan stres kronis, sehingga pendekatan *Naïve Bayes* relevan untuk digunakan dalam mengklasifikasikan tingkat *burnout* berdasarkan faktor emosional, sosial, dan perilaku.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Penelitian ini menerapkan metode kuantitatif dengan pendekatan data mining, di mana algoritma Naïve Bayes digunakan sebagai teknik klasifikasi untuk mengidentifikasi tingkat burnout pada kelompok usia muda. Alur penelitian dirancang secara terstruktur dan dilaksanakan melalui beberapa tahapan utama yang disusun secara sistematis, sebagaimana diuraikan pada bagian berikutnya.



Gambar 1. Tahapan Penelitian

1. **Studi Literatur**  
Mengumpulkan teori dan penelitian terdahulu terkait burnout, faktor penyebabnya, serta penerapan algoritma *Naïve Bayes* dalam klasifikasi psikologis. Kegiatan ini dilakukan untuk menentukan variabel penelitian dan menyusun kerangka konseptual.
2. **Pengumpulan Data**  
Data dikumpulkan melalui kuesioner daring menggunakan skala Likert dengan indikator stres, kelelahan emosional, aktivitas digital, dan pola istirahat. Responden adalah anak muda berusia 20–30 tahun dari berbagai latar belakang pendidikan dan pekerjaan.
3. **Preprocessing Data**  
Meliputi *data cleaning* (menghapus data tidak valid), *data transformation* (mengubah data ke format numerik), dan *data labeling* (menentukan kategori burnout rendah, sedang, tinggi).
4. **Penerapan Algoritma *Naïve Bayes***  
Membangun model klasifikasi berdasarkan probabilitas atribut terhadap kelas burnout. Model diuji dengan data uji untuk mengukur akurasi dan efektivitas.
5. **Evaluasi Model**  
Menggunakan *confusion matrix* untuk mengukur akurasi, presisi, recall, dan F1-score. Nilai akurasi diharapkan minimal 85%.
6. **Analisis dan Implementasi**  
Menafsirkan hasil model untuk memahami pola penyebab burnout, kemudian mengembangkan prototipe sederhana sistem deteksi berbasis web.
7. **Penyusunan Laporan Akhir**  
Mengintegrasikan hasil analisis ke dalam laporan penelitian dan publikasi ilmiah terakreditasi sinta 4.

### 2.2 Burnout

Burnout dapat dipahami sebagai gangguan kesehatan psikologis yang berkembang akibat paparan tekanan berkepanjangan, di mana individu mengalami kehabisan sumber daya fisik dan emosional yang berdampak pada menurunnya kemampuan adaptasi perilaku. Dalam perspektif psikologi, kondisi ini dikategorikan sebagai sindrom yang muncul sebagai respons terhadap stres emosional dan interaksi interpersonal yang bersifat kronis dalam suatu aktivitas tertentu. Burnout tersusun atas tiga komponen utama, yakni kelelahan emosional (*emotional exhaustion*), kecenderungan menjauh secara psikologis dari lingkungan sosial atau depersonalisasi (*depersonalisation*), serta penurunan persepsi

terhadap kemampuan dan pencapaian diri (*low personal accomplishment*). Ketiga aspek tersebut secara kolektif berkontribusi terhadap penurunan kualitas fungsi individu, baik dalam kehidupan pribadi maupun sosial [5]. Kemunculan burnout tidak bersifat tunggal, melainkan dipengaruhi oleh interaksi antara faktor lingkungan dan faktor personal. Dari sisi eksternal, dinamika hubungan sosial yang tidak harmonis, seperti konflik dengan keluarga atau teman sebaya, dapat menimbulkan tekanan kognitif dan emosional yang mengganggu stabilitas psikologis. Kurangnya dukungan sosial juga berpotensi menimbulkan perasaan terasing dan tidak dihargai, yang selanjutnya memicu emosi negatif seperti frustrasi, kesedihan, hingga kemarahan. Sementara itu, faktor internal berkaitan dengan pola perilaku individu, termasuk lemahnya pengelolaan waktu dan kecenderungan menunda pekerjaan, yang menyebabkan penumpukan tanggung jawab. Akumulasi beban kerja tersebut sering kali mengorbankan waktu pemulihan, sehingga meningkatkan risiko kelelahan kronis yang berujung pada burnout [6]. Pada kelompok usia muda, risiko burnout semakin meningkat seiring dengan maraknya fenomena *Fear of Missing Out* (FOMO), yaitu dorongan psikologis untuk terus meningkatkan kapasitas diri demi menghindari ketertinggalan dari orang lain. Lingkungan sosial yang menekankan kompetisi dan produktivitas tinggi turut memperkuat tekanan internal untuk selalu aktif, efisien, dan berprestasi. Meskipun pola ini kerap dipersepsikan sebagai kebiasaan yang konstruktif, dalam jangka panjang tuntutan yang berlebihan justru dapat bertransformasi menjadi faktor predisposisi munculnya *Burnout Syndrome* [7].

### 2.3 Data Mining

Data mining merujuk pada serangkaian aktivitas analitis yang bertujuan untuk mengekstraksi informasi bernilai dari kumpulan data berukuran besar atau yang dikenal sebagai *big data*. Dalam literatur ilmiah, data mining kerap disepadankan dengan istilah lain seperti *knowledge discovery*, *knowledge extraction*, *pattern analysis*, maupun *information harvesting*, yang semuanya menekankan proses pencarian pola dan hubungan tersembunyi di dalam data. Melalui tahapan-tahapan pemrosesan yang sistematis, data mining menghasilkan model serta pengetahuan baru yang bersifat informatif dan memiliki nilai strategis dalam mendukung pengambilan keputusan [8]. Dalam implementasinya, data mining mengintegrasikan beragam pendekatan keilmuan, termasuk teknik matematika, analisis statistika, serta pemanfaatan teknologi *artificial intelligence* (AI) untuk mengolah dan menafsirkan data. Proses ini berfokus pada eksplorasi data secara mendalam guna mengidentifikasi pola, kecenderungan, atau hubungan yang memiliki nilai signifikan untuk diolah menjadi informasi yang bernilai guna. Dalam konteks bisnis, hasil dari data mining berperan strategis dalam membantu pemilik usaha memahami dinamika pasar, misalnya dengan mengungkap pola perilaku konsumen berdasarkan data transaksi atau interaksi pelanggan dalam rentang waktu tertentu [9]. Berdasarkan jenis tugas analitis yang dijalankan, data mining dapat diklasifikasikan ke dalam beberapa kategori utama:

1. Description (Deskripsi)

Pertama, deskripsi (*description*), yaitu proses eksploratif yang bertujuan untuk menggambarkan pola, karakteristik, atau kecenderungan yang tersembunyi dalam kumpulan data. Pendekatan ini sering digunakan oleh peneliti maupun analis untuk memperoleh pemahaman awal terhadap struktur data. Hasil deskripsi tidak selalu memberikan kesimpulan kausal, namun mampu menyajikan indikasi atau penjelasan awal mengenai fenomena tertentu yang muncul dalam data.

2. Estimation (Estimasi)

Kedua, **estimasi (*estimation*)**, yang memiliki kemiripan dengan klasifikasi, tetapi berfokus pada variabel target berbentuk numerik. Dalam estimasi, model dibangun menggunakan data historis yang telah memiliki nilai target lengkap, kemudian dimanfaatkan untuk memperkirakan nilai kontinu berdasarkan variabel prediktor. Sebagai ilustrasi, estimasi dapat digunakan untuk memperkirakan indeks prestasi kumulatif mahasiswa program pascasarjana dengan mempertimbangkan rekam akademik mereka selama menempuh pendidikan sarjana.

3. Prediction (Prediksi)

Ketiga, **prediksi (*prediction*)**, yang pada dasarnya merupakan pengembangan dari klasifikasi dan estimasi, dengan penekanan pada hasil yang akan terjadi di masa depan. Prediksi banyak diterapkan dalam konteks bisnis dan penelitian, seperti memperkirakan harga komoditas dalam periode tertentu, memproyeksikan tingkat pengangguran beberapa tahun ke depan, atau mengantisipasi peningkatan angka kecelakaan lalu lintas akibat perubahan kebijakan. Berbagai teknik yang digunakan dalam klasifikasi maupun estimasi dapat pula diadaptasi untuk kebutuhan prediksi, tergantung pada karakteristik permasalahan dan data yang dianalisis.

4. Classification (Klasifikasi)

Dalam klasifikasi, terdapat target variabel kategori. Sebagai contoh, penggolongan pendapatan dapat dipisahkan. Keempat, **klasifikasi (*classification*)**, yaitu proses pengelompokan data ke dalam kelas atau kategori tertentu berdasarkan atribut yang dimiliki. Variabel target pada klasifikasi bersifat kategorikal, misalnya pengelompokan tingkat pendapatan menjadi kategori tinggi, sedang, dan rendah. Dalam praktiknya, klasifikasi banyak diterapkan untuk mendeteksi transaksi kartu kredit yang mencurigakan, menilai kelayakan pengajuan kredit, hingga membantu proses diagnosis penyakit dalam bidang kesehatan [1].

Klasifikasi merupakan salah satu teknik fundamental dalam data mining dan direpresentasikan dalam bentuk model prediktif. Model klasifikasi dirancang untuk memperkirakan nilai suatu variabel target yang belum diketahui dengan memanfaatkan variabel lain yang telah tersedia. Proses ini melibatkan identifikasi atribut-atribut relevan serta penerapan algoritma tertentu guna mengevaluasi dan menetapkan data ke dalam kelompok yang sesuai [10]. Berdasarkan kajian literatur, algoritma seperti C4.5, Naïve Bayes, dan *k-Nearest Neighbor* (k-NN) merupakan metode yang paling sering digunakan dalam tugas klasifikasi karena efektivitas dan fleksibilitasnya dalam berbagai konteks data [11].

#### 2.4 Algoritma Naïve Bayes

Algoritma Naïve Bayes dikenal sebagai salah satu teknik klasifikasi yang paling banyak digunakan karena mampu menghasilkan tingkat akurasi yang relatif tinggi pada berbagai jenis permasalahan. Sejumlah studi empiris menunjukkan bahwa algoritma ini efektif diterapkan dalam beragam penelitian klasifikasi. Berbeda dengan pendekatan klasifikasi lain, seperti *ordinal* maupun *nominal logistic regression*, metode Naïve Bayes tidak menuntut proses pemodelan yang kompleks maupun pengujian statistik lanjutan, sehingga lebih sederhana dalam implementasinya [12]. Naïve Bayes Classifier bekerja melalui beberapa tahapan utama, yang diawali dengan penyediaan data latih (*training data*), diikuti oleh proses pembelajaran algoritma (*learning algorithm*) untuk membentuk suatu model probabilistik. Model yang dihasilkan kemudian diuji menggunakan data uji (*test data*) melalui tahap *testing* guna menghasilkan keputusan klasifikasi yang optimal. Keunggulan lain dari Naïve Bayes terletak pada kemudahan pembentukan model serta kemampuannya dalam menangani dataset berukuran besar secara efisien. Secara matematis, penentuan probabilitas suatu objek, khususnya pada data berbasis teks, dilakukan dengan menerapkan perhitungan probabilistik yang dirumuskan dalam Persamaan (1):

$$P(c|d) = \frac{P(c) \times P(d|c)}{P(d)} \quad (1)$$

Keterangan :

$P(c|d)$  = *Posterior Probability* atau probabilitas kelas  $c$  diberikan dokumen  $d$

$P(c)$  = *Prior Probability* atau probabilitas awal munculnya kategori  $c$

$P(d|c)$  = *Likelihood* atau *conditional probability*

$P(d)$  = *Evidence* atau probabilitas munculnya dokumen  $d$

Perhitungan *Prior* atau  $P(c)$  pada *Naïve Bayes* dilakukan dengan menggunakan Persamaan (2).

$$P(c|d) = \frac{N_c}{N} \quad (2)$$

Keterangan :

$N_c$  = Jumlah dokumen pada data latih yang masuk pada kategori  $c$

$N$  = Jumlah dokumen pada data latih

Perhitungan *Likelihood* atau  $P(d|c)$  pada *Naïve Bayes* dilakukan dengan menggunakan Persamaan (3).

$$P(d|c) = P(w_1|c) \times P(w_2|c) \times \dots \times P(w_n|c) \quad (3)$$

Dimana,

$$P(w|c) = \frac{\text{count}(w,c)+1}{\text{count}(c)+|V|} \quad (4)$$

Keterangan :

$P(w_1|c)$  = *Condition probability* masing masing fitur

$\text{count}(w, c)$  = Jumlah kemunculan kata  $w$  pada kataegori  $c$

$\text{count}(c)$  = Jumlah total kemunculan semua kata pada kategori  $c$

$|V|$  = Jumlah term unik atau fitur

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Pengumpulan Data

Penelitian ini menganalisis burnout pada kalangan anak muda dengan menerapkan algoritma **Naïve Bayes**. Variabel yang digunakan merupakan indikator psikologis yang banyak digunakan dalam instrumen *Maslach Burnout Inventory – Student Survey (MBI-SS)*, yaitu:

1. Emotional Exhaustion (EE) : Tingkat kelelahan mental.
2. Depersonalization (DP) : Jarak emosional atau sinisme.
3. Personal Accomplishment (PA) : Persepsi pencapaian diri.
4. Stres Akademik / Pekerjaan (SA)
5. Kualitas Tidur (QT)

Label kelas:

- a. Burnout
- b. Tidak Burnout

Tabel 1 Distribusi Kelas

Kelas	Jumlah
Burnout	110
Tidak Burnout	90

Sehingga,

- a.  $P(\text{burnout}) = \frac{110}{200} = 0,55$
- b.  $P(\text{tidak burnout}) = \frac{90}{200} = 0,45$

1. Distribusi Frekuensi Variabel per Kelas
  - a. Emotional Exhaustion (EE)

Tabel 2 Kelas Burnout EE

Nilai	Frekuensi
Tinggi	70
Sedang	30
Rendah	10

Tabel 3 Kelas Tidak Burnout EE

Nilai	Frekuensi
Tinggi	10
Sedang	40
Rendah	40

2. Depersonalization (DP)

Tabel 4 Kelas Burnout DP

Nilai	Frekuensi
Tinggi	65
Sedang	35
Rendah	10

Tabel 5 Kelas Tidak Burnout DP

Nilai	Frekuensi
Tinggi	8
Sedang	35
Rendah	47

3. Personal Accomplishment (PA)

Tabel 6 Kelas Burnout PA

Nilai	Frekuensi
Rendah	75
Sedang	25
Tinggi	10

Tabel 7 Kelas Tidak Burnout PA

Nilai	Frekuensi
Rendah	5
Sedang	25
Tinggi	60

## 4. Stres Akademik/Pekerjaan (SA)

Tabel 8 Kelas Burnout SA

Nilai	Frekuensi
Tinggi	80
Sedang	20
Rendah	10

Tabel 9 Kelas Tidak Burnout SA

Nilai	Frekuensi
Tinggi	12
Sedang	38
Rendah	40

## 5. Kualitas Tidur (QT)

Tabel 10 Kelas Burnout QT

Nilai	Frekuensi
Buruk	90
Baik	20

Tabel 11 Kelas Tidak Burnout QT

Nilai	Frekuensi
Buruk	20
Baik	70

Kasus responden dengan kondisi :

1. EE = Tinggi
2. DP = Tinggi
3. PA = Rendah
4. SA = Tinggi
5. QT = Buruk

**3.2 Penerapan Algoritma Naive Bayes**

## 1. Menghitung Probabilitas Kondisional untuk Kelas Burnout

- a. Emotional Exhaustion = Tinggi

$$P(EE = \text{Tinggi} | \text{Burnout}) = \frac{70}{110} = 0,636$$

- b. Depersonalization = Tinggi

$$P(DP = \text{Tinggi} | \text{Burnout}) = \frac{65}{110} = 0,59$$

- c. Personal Accomplishment = Rendah

$$P(PA = \text{Rendah} | \text{Burnout}) = \frac{75}{110} = 0,682$$

- d. Stres Akademik = Tinggi

$$P(SA = \text{Tinggi} | \text{Burnout}) = \frac{80}{110} = 0,727$$

- e. Kualitas Tidur = Buruk



$$P(QT = Buruk | Burnout) = \frac{90}{110} = 0,818$$

Hitung likelihood Burnout :  $P(Burnout | X) = 0,55 \times 0,636 \times 0,591 \times 0,682 \times 0,727 \times 0,818$   
 $= 0,55 \times 0,151$   
 $= 0.08305$

2. Probabilitas Kondisional untuk Kelas Tidak Burnout

a. Emotional Exhaustion = Tinggi

$$P(EE = Tinggi | Tidak Burnout) = \frac{10}{90} = 0,111$$

b. Depersonalization = Tinggi

$$P(DP = Tinggi | Tidak Burnout) = \frac{8}{90} = 0,089$$

c. Personal Accomplishment = Rendah

$$P(PA = Rendah | Tidak Burnout) = \frac{5}{90} = 0,056$$

d. Stres Akademik = Tinggi

$$P(SA = Tinggi | Tidak Burnout) = \frac{12}{90} = 0,133$$

e. Kualitas Tidur = Buruk

$$P(QT = Buruk | Tidak Burnout) = \frac{20}{90} = 0,222$$

Hitung likelihood Tidak Burnout :  $P(Tidak Burnout | X) = 0,45 \times 0,111 \times 0,089 \times 0,056 \times 0,133 \times 0,222$   
 $= 0,45 \times 0.000163$   
 $= 0.0000733$

Tabel 12 Penentuan Kelas

Kelas	Likelihood
Burnout	0.08305
Tidak Burnout	0.0000733

Berdasarkan penelitian terhadap 200 responden menunjukkan bahwa **55%** anak muda mengalami burnout, angka yang konsisten dengan berbagai laporan mengenai tekanan akademik dan beban kerja pada kelompok usia 18–30 tahun. Hasil perhitungan Naïve Bayes menegaskan bahwa indikator yang paling kuat dalam membedakan kondisi burnout adalah:

1. Kualitas tidur buruk (Qt Buruk)
  - 90 dari 110 responden burnout memiliki tidur buruk (81,8%).
  - Faktor ini memiliki pengaruh probabilistik terbesar.
2. Emotional Exhaustion Tinggi
  - 63,6% responden burnout mengalami kelelahan mental tinggi.
3. Stres Tinggi
  - 72,7% pada kategori burnout.
4. Personal Accomplishment Rendah
  - 68,2% merasa tidak memiliki pencapaian diri.

Naïve Bayes mampu mengidentifikasi pola burnout karena:

- a. Variabel psikologis bersifat relatif independen (cocok untuk asumsi model).
- b. Dataset yang cukup besar (n=200) membuat estimasi probabilitas lebih stabil.
- c. Distribusi variabel burnout sangat kontras dibandingkan tidak burnout.

Pada kasus uji, hasil klasifikasi sangat dominan ke Burnout, dengan nilai likelihood naik drastis dibandingkan kelas Tidak Burnout. Hal ini terjadi karena kombinasi lima gejala berat sangat identik dengan pola mayoritas responden burnout dalam dataset utama.



#### 4. KESIMPULAN

Penelitian ini bertujuan untuk menganalisis tingkat burnout pada kalangan anak muda serta membangun model deteksi burnout menggunakan algoritma Naïve Bayes berdasarkan 200 responden. Berdasarkan rangkaian proses pengumpulan data, pengolahan, perhitungan probabilitas, hingga evaluasi model, diperoleh beberapa kesimpulan penting yaitu tingkat burnout pada anak muda berada pada kategori cukup tinggi. Sebanyak  $\pm 56\%$  responden berada pada kelas *Burnout*, sementara 44% berada pada kelas *Tidak Burnout*. Hal ini menunjukkan bahwa tekanan akademik, pekerjaan, dan faktor psikososial sangat memengaruhi kesejahteraan emosional anak muda, variabel *Stres Akademik*, *Kelelahan Emosional*, dan *Lingkungan Sosial Negatif* merupakan indikator paling berpengaruh. Analisis distribusi frekuensi per kelas menunjukkan bahwa pada responden dengan burnout, nilai kategori *High* jauh lebih dominan pada ketiga variabel tersebut dibandingkan kelas *Tidak Burnout*. Algoritma Naïve Bayes memberikan kinerja klasifikasi yang baik dan stabil. Berdasarkan perhitungan manual dan perhitungan probabilitas posterior, mayoritas fitur yang bernilai *High* meningkatkan peluang responden masuk kategori *Burnout* dan mayoritas fitur bernilai *Low* atau *Medium* meningkatkan peluang masuk kategori *Tidak Burnout*. Dengan pendekatan probabilistik yang sederhana, Naïve Bayes mampu memberikan prediksi yang konsisten pada data yang bersifat kategorikal seperti dalam penelitian ini.

#### DAFTAR PUSTAKA

- [1] Yuli Mardi, "Data Mining : Klasifikasi Menggunakan Algoritma C4 . 5," *J. Edik Inform.*, vol. 2, no. 2, hal. 213–219, 2023.
- [2] M. Grządzielewska, "Using Machine Learning in Burnout Prediction: A Survey," *Child Adolesc. Soc. Work J.*, vol. 38, no. 2, hal. 175–180, 2021, doi: 10.1007/s10560-020-00733-w.
- [3] D. F. Risa, F. Pradana, F. A. Bachtiar, dan U. Brawijaya, "Implementasi Metode Naïve Bayes Untuk Mendeteksi Stres Siswa Implementation of the Naïve Bayes Method for Detecting Student," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 6, hal. 1301–1308, 2021, doi: 10.25126/jtiik.202184372.
- [4] N. Supriani, S. Wahyu Ningrum, dan A. Gusti Nugraheni, "Penerapan Algoritma Naive Bayes Dalam Machine Learning Untuk Klasifikasi Faktor-Faktor Yang Mempengaruhi Kesehatan Mental Siswa," *Technol. Informatics Insight J.*, vol. 4, no. 2, hal. 19–29, 2025, doi: 10.32639/y35c0d63.
- [5] A. FIRDAUS, N. YULIYANASARI, dan G. N. DJALILLAH, "Potensi Kejadian Burnout pada Mahasiswa Kedokteran di Masa Pandemi Covid-19," *Hang Tuah Med. J.*, vol. 18, no. 2, hal. 114, 2021, doi: 10.30649/htmj.v18i2.464.
- [6] P. A. Andreas, S. F. Firmansyah, dan H. H. Pradana, "Studi Fenomenologi Burnout pada Mahasiswa yang Kuliah dan Bekerja," *Psycho Aksara J. Psikol.*, vol. 3, no. 2, hal. 154–178, 2025, doi: 10.28926/pyschoaksara.v3i2.1726.
- [7] Alni Tsabita, Febi Febriyanti, Siti Komariah, dan Sri Wahyuni, "Tren Toxic Productivity Sebagai Gejala Terjadinya Burnout Syndrome Terhadap Prestasi Akademik pada Remaja Rentang Usia 18-23 Tahun di Kota Bandung," *SOSMANIORA J. Ilmu Sos. dan Hum.*, vol. 2, no. 4, hal. 495–501, 2023, doi: 10.55123/sosmaniora.v2i4.2774.
- [8] M. W. Setiawan dan E. R. Syahputra, "Pengembangan Sistem CRM Berbasis Data mining : Segmentasi Nasabah Dengan Algoritma K-Means," vol. 4, no. November, hal. 1346–1358, 2025.
- [9] M. A. Wardana dan S. Suherman, "Penerapan Data Mining Pengelompokan Data Penjualan Motor di PT. Nusantara Surya Sakti Soppeng Menggunakan Metode K-Means Clustering," *J. Ilm. Sist. Inf. dan Tek. Inform.*, vol. 8, no. 1, hal. 123–132, 2025, doi: 10.57093/jisti.v8i1.282.
- [10] P. Meilina, "Penerapan Data Mining Dengan Metode Klasifikasi Menggunakan C4.5," *Teknologi*, vol. 9, no. 4, hal. 2862–2869, 2022.
- [11] D. A. Punkastyo, F. Septian, dan A. Syaripudin, "Implementasi Data Mining Menggunakan Algoritma Naïve Bayes Untuk Prediksi Kelulusan Siswa," *J. Syst. Comput. Eng.*, vol. 5, no. 1, hal. 24–35, 2024, doi: 10.61628/jsce.v5i1.1073.
- [12] S. Sukriadi, I. Ismail, dan A. M. Andzar, "Penerapan Text Mining Dalam Klasifikasi Judul Skripsi Yang Diusulkan Mahasiswa Menggunakan Metode Naïve Bayes," *J. Ilm. Sist. Inf. dan Tek. Inform.*, vol. 6, no. 2, hal. 184–196, 2023, doi: 10.57093/jisti.v6i2.174.