



## Prediksi dan Pencegahan Risiko Burnout pada Pekerja Fleksibel Menggunakan Algoritma Random Forest

Noha Noor Fauziah Mk<sup>1,\*</sup>, Dimas Lukman Hakim<sup>1</sup>, Ainun Cahyani<sup>1</sup>, Findi Ayu Sariasih<sup>1</sup>, Syifa Nur Rakhmah<sup>2</sup>, Imam Sutoyo<sup>2</sup>

<sup>1</sup> Fakultas Teknik & Informatika, Program Studi Informatika, Universitas Bina Sarana Informatika, Jakarta Pusat, Indonesia

<sup>2</sup> Fakultas Teknik & Informatika, Program Studi Teknologi Informasi, Universitas Bina Sarana Informatika, Jakarta Pusat, Indonesia

Email: <sup>1,\*</sup>[nohafauziah@gmail.com](mailto:nohafauziah@gmail.com), <sup>2</sup>[15230193@bsi.ac.id](mailto:15230193@bsi.ac.id), <sup>3</sup>[15230225@bsi.ac.id](mailto:15230225@bsi.ac.id), <sup>4</sup>[findi.fav@bsi.ac.id](mailto:findi.fav@bsi.ac.id), <sup>5</sup>[syifa.snk@bsi.ac.id](mailto:syifa.snk@bsi.ac.id),

<sup>6</sup>[imam.ity@bsi.ac.id](mailto:imam.ity@bsi.ac.id)

(\* : coresponding author)

**Abstrak**—Pekerja fleksibel dengan skema remote, hybrid, dan freelance menghadapi risiko burnout yang sulit dideteksi secara dini akibat pola kerja tidak teratur dan batasan waktu kerja yang kabur. Pemantauan burnout konvensional yang bergantung pada survei manual bersifat statis dan kurang sensitif terhadap dinamika perubahan psikologis pekerja. Penelitian ini bertujuan mengembangkan sistem prediksi burnout berbasis machine learning untuk pekerja fleksibel yang mampu memberikan prediksi risiko secara real-time disertai rekomendasi pencegahan yang dipersonalisasi. Metode yang digunakan adalah Random Forest Classifier dengan dataset dari Kaggle berjudul "Mental Health & Burnout in the Workplace" yang mencakup 5.000 observasi. Pengembangan sistem mengikuti pendekatan Agile dan diimplementasikan melalui aplikasi web berbasis Streamlit. Tahap preprocessing meliputi transformasi label biner, eliminasi data leakage, one-hot encoding, penanganan ketidakseimbangan kelas menggunakan SMOTE, dan stratified split dengan rasio 90:10. Model Random Forest dikonfigurasi dengan 800 trees, max\_depth 20, dan hyperparameter optimal lainnya. Hasil evaluasi menunjukkan model mencapai akurasi 87% dengan precision 0,89, recall 0,91, dan F1-score 0,90 pada kelas burnout. Analisis feature importance mengidentifikasi CareerGrowthScore, StressLevel, dan ProductivityScore sebagai faktor dominan. Sistem menyediakan prediksi real-time dengan latency <2 detik dan rekomendasi pencegahan yang disesuaikan dengan profil risiko individual. Kontribusi penelitian ini memberikan solusi praktis untuk self-monitoring kesehatan mental pekerja fleksibel secara mandiri, sekaligus menyediakan instrumen pemantauan kesejahteraan bagi organisasi dengan tenaga kerja remote. Pengujian black-box testing memvalidasi seluruh fungsionalitas berjalan sesuai spesifikasi.

**Kata Kunci:** Burnout; Machine Learning; Pekerja Fleksibel; Prediksi Real-time; Random Forest.

**Abstract**—Flexible workers operating under remote, hybrid, and freelance schemes face burnout risks that are difficult to detect early due to irregular work patterns and blurred work-time boundaries. Conventional burnout monitoring relying on manual surveys is static and lacks sensitivity to the dynamics of workers' psychological changes. This study aims to develop a machine learning-based burnout prediction system for flexible workers capable of providing real-time risk predictions accompanied by personalized prevention recommendations. The method employed is Random Forest Classifier using a dataset from Kaggle titled "Mental Health & Burnout in the Workplace" encompassing 5,000 observations. System development follows the Agile approach and is implemented through a Streamlit-based web application. Preprocessing stages include binary label transformation, data leakage elimination, one-hot encoding, class imbalance handling using SMOTE, and stratified split with a 90:10 ratio. The Random Forest model is configured with 800 trees, max\_depth of 20, and other optimal hyperparameters. Evaluation results demonstrate that the model achieves 87% accuracy with precision of 0.89, recall of 0.91, and F1-score of 0.90 for the burnout class. Feature importance analysis identifies CareerGrowthScore, StressLevel, and ProductivityScore as dominant factors. The system provides real-time predictions with latency <2 seconds and prevention recommendations tailored to individual risk profiles. This research contributes a practical solution for self-monitoring mental health among flexible workers and provides organizations with an instrument for monitoring remote workforce well-being. Black-box testing validates that all functionalities operate according to specifications.

**Keywords:** Burnout; Flexible Workers; Machine Learning; Real-time Prediction; Random Forest.

### 1. PENDAHULUAN

Perkembangan teknologi Artificial Intelligence (AI) dan machine learning telah mendorong transformasi fundamental dalam ekosistem kerja kontemporer. Teknologi ini tidak hanya meningkatkan efisiensi operasional, tetapi juga membuka peluang baru dalam menganalisis pola kerja dan kondisi psikologis pekerja secara real-time. Kemampuan analitik berbasis data memungkinkan deteksi dini terhadap potensi stres atau burnout dengan pendekatan yang lebih objektif dan terukur dibandingkan metode konvensional. Pergeseran paradigmatik dari model kerja tradisional menuju skema fleksibel (remote, hybrid, freelancing) mengalami akselerasi signifikan pasca pandemi COVID-19. Meskipun menawarkan berbagai keuntungan, evidensi empiris menunjukkan risiko signifikan terhadap kesejahteraan pekerja. Penelitian di Indonesia menunjukkan bahwa Work-From-Home (WFH) dapat menurunkan produktivitas, meningkatkan stres kerja, dan mengganggu keseimbangan kehidupan kerja [1], [2]. Systematic literature review mengonfirmasi pekerja remote menghadapi risiko burnout lebih tinggi akibat peningkatan beban kerja, isolasi profesional, dan ketidakseimbangan work-life balance [3], [4].

Kaburnya batas waktu kerja-istirahat, berkurangnya interaksi sosial, dan fenomena "always-on culture" meningkatkan risiko kelelahan kronis dan turnover intention [5]. Isolasi sosial selama WFH meningkatkan loneliness yang berkontribusi terhadap stres kerja dan kelelahan emosional [6]. Di konteks Indonesia, penelitian terkini menunjukkan bahwa meskipun Flexible Working Arrangement (FWA) memiliki potensi meningkatkan produktivitas dan kesejahteraan karyawan di era digital, tantangan dalam memisahkan waktu kerja dan waktu pribadi tetap menjadi isu



signifikan [7], [8]. Studi empiris membuktikan bahwa FWA memiliki pengaruh terhadap job satisfaction, namun efek ini dimoderasi oleh tingkat work stress dan emotional exhaustion. Hal ini mengindikasikan bahwa implementasi FWA tanpa mekanisme pemantauan kesehatan mental yang memadai justru dapat meningkatkan risiko burnout pada populasi pekerja fleksibel. Pemantauan burnout konvensional bergantung pada survei cross-sectional yang menciptakan gap temporal signifikan antara onset gejala dan deteksi, menunda intervensi preventif. Instrumen self-report seperti Maslach Burnout Inventory (MBI), meskipun valid, tidak menyediakan feedback real-time dan analisis faktor risiko individual spesifik, menghasilkan rekomendasi pencegahan yang generik dan kurang kontekstual terhadap kondisi unik setiap pekerja.

Penelitian terdahulu menunjukkan bahwa flexible working arrangement memiliki dampak signifikan terhadap kesejahteraan karyawan, termasuk potensi penurunan risiko burnout melalui mekanisme persepsi dukungan organisasi [9]. Namun, flexible working arrangement tanpa batasan waktu yang jelas justru dapat menimbulkan tekanan berlebih dan kelelahan akut pada pekerja. Burnout adalah sindrom psikologis akibat kegagalan mengelola tekanan pekerjaan berkepanjangan, ditandai kelelahan emosional, depersonalisasi, dan berkurangnya pencapaian personal [10]. Faktor pemicunya meliputi beban kerja berlebih, tuntutan yang tidak terprediksi, ambiguitas peran, minimnya dukungan sosial, dan ketidakadilan organisasi. Pada pekerja fleksibel, risiko ini semakin sulit diidentifikasi tanpa analitik berbasis data karena kondisi psikologis mereka cenderung berubah secara dinamis [11].

Upaya prediksi burnout menggunakan pendekatan machine learning telah dilakukan dalam beberapa penelitian terdahulu dengan hasil yang menjanjikan. Penelitian oleh [12] mengembangkan model prediksi burnout pada programmer dengan menggunakan pendekatan pengenalan pola. Data dikumpulkan melalui kuesioner yang terdiri dari 12 indikator pola kerja serta 22 item Maslach Burnout Inventory (MBI). Pada tahap analisis awal, model Logistic Regression menghasilkan akurasi sebesar 65%, namun meningkat menjadi 82,61% setelah dilakukan proses feature selection yang menyisakan tiga fitur paling berpengaruh.

Sementara itu, penelitian oleh [13] memanfaatkan algoritma Gradient Boosting Classifier untuk memprediksi burnout dan emotional exhaustion pada tenaga kesehatan, mencapai akurasi 75,8% pada dimensi kelelahan emosional dan 76,8% untuk tingkat burnout keseluruhan. Faktor yang paling kuat memengaruhi prediksi adalah kelelahan (fatigue), dukungan serta kepercayaan terhadap manajemen, dan kepuasan kerja, sementara data demografis memiliki kontribusi prediktif yang lebih rendah. Dalam konteks kesehatan mental, pendekatan machine learning telah terbukti efektif untuk klasifikasi kondisi psikologis dengan tingkat akurasi yang memadai [14].

Perkembangan terkini menunjukkan framework AI terintegrasi telah dikembangkan untuk prediksi multi-outcome termasuk burnout dengan implementasi real-time melalui aplikasi web berbasis Streamlit [15]. Survey komprehensif menunjukkan bahwa pendekatan machine learning dalam prediksi burnout menawarkan keunggulan dibandingkan metode tradisional dalam menangani dataset besar dan menghasilkan model data-driven yang lebih akurat [16]. Pendekatan explainable machine learning menggunakan SHAP mampu memprioritaskan faktor-faktor kunci yang berkontribusi terhadap burnout dengan transparansi interpretasi yang tinggi [17].

Kebaruan penelitian ini terletak pada beberapa aspek inovatif. Pertama, sistem ini mengintegrasikan prediksi burnout multi-dimensi dengan sistem rekomendasi berstrata yang disesuaikan dengan tingkat risiko individual. Kedua, sistem memungkinkan self-assessment on-demand dengan interpretasi faktor risiko spesifik melalui feature importance analysis, berbeda dengan survei statis konvensional. Ketiga, implementasi berbasis web memfasilitasi aksesibilitas tanpa instalasi untuk pemantauan berkelanjutan pada pekerja dengan mobilitas tinggi. Keempat, sistem menyediakan feedback instan yang dipersonalisasi. Berbeda dengan penelitian [12] yang mencapai akurasi 82,61% dengan pendekatan Logistic Regression dan [13] dengan akurasi 76,8% menggunakan Gradient Boosting Classifier, sistem ini tidak hanya meningkatkan akurasi prediksi hingga 87% tetapi juga menyediakan interpretasi faktor risiko secara real-time dan rekomendasi pencegahan yang dipersonalisasi—fitur yang tidak tersedia pada penelitian terdahulu.

Berdasarkan identifikasi permasalahan di atas, penelitian ini bertujuan mengembangkan sistem prediksi burnout berbasis machine learning khusus untuk pekerja fleksibel yang mampu memberikan prediksi risiko secara real-time, memberitahu faktor terbesar penyebabnya dan disertai rekomendasi pencegahan yang dipersonalisasi. Tujuan spesifik penelitian meliputi: (1) membangun model klasifikasi burnout menggunakan algoritma Random Forest dengan performa optimal, (2) mengidentifikasi dan mengkuantifikasi faktor-faktor kunci yang berkontribusi terhadap burnout pada pekerja fleksibel, (3) mengimplementasikan sistem dalam bentuk aplikasi web yang user-friendly berbasis Streamlit, dan (4) menyediakan mekanisme rekomendasi pencegahan yang disesuaikan dengan profil risiko individual.

Untuk memfokuskan penelitian, ditetapkan beberapa batasan masalah. Penelitian ini dibatasi pada pekerja dengan skema fleksibel (remote, hybrid, freelance) dan fokus pada prediksi tingkat burnout serta pemberian rekomendasi pencegahan melalui aplikasi web. Model yang dikembangkan berperan sebagai alat bantu pemantauan (screening tool) dan bukan sebagai instrumen diagnostik klinis. Hasil prediksi memerlukan interpretasi dan validasi oleh profesional kesehatan mental untuk keperluan intervensi psikologis yang komprehensif.

Kontribusi penelitian ini diharapkan dapat memberikan manfaat praktis pada berbagai level. Bagi pekerja fleksibel, sistem ini menyediakan sarana deteksi dini burnout secara mandiri dengan feedback instan yang actionable. Bagi organisasi, sistem dapat digunakan sebagai instrumen pemantauan kesejahteraan tenaga kerja remote secara agregat. Bagi pengembangan sistem kesehatan mental berbasis teknologi, penelitian ini berkontribusi pada body of knowledge mengenai implementasi machine learning untuk health informatics dengan fokus pada occupational health psychology.

## 2. METODOLOGI PENELITIAN

### 2.1 Metodologi Penelitian

Metodologi penelitian merupakan kerangka dasar yang digunakan untuk menyelesaikan suatu permasalahan secara sistematis. Istilah ini merujuk pada konsep atau pendekatan yang membantu peneliti dalam merumuskan strategi pemecahan masalah melalui tahapan-tahapan yang terstruktur. Kerangka kerja penelitian yang digunakan dalam studi ini dapat dilihat pada Gambar 1 berikut:



**Gambar 1.** Kerangka Kerja Penelitian

Penjelasan mengenai Gambar 1 yang menggambarkan kerangka kerja penelitian tersebut dapat diuraikan sebagai berikut:

- Studi Literatur, pada tahap ini peneliti mengumpulkan referensi terkait burnout, pekerja fleksibel, serta penerapan machine learning. Studi dilakukan untuk memahami konsep burnout, faktor risikonya, dan alasan pemilihan algoritma Random Forest.
- Identifikasi Masalah, pekerja fleksibel rentan mengalami burnout akibat pola kerja yang tidak teratur dan batasan kerja yang tidak jelas. Selain itu, belum tersedia sistem prediksi burnout yang cepat dan akurat berbasis machine learning sehingga diperlukan model khusus.
- Analisa Kebutuhan Sistem, tahap ini mengidentifikasi kebutuhan pengguna melalui kajian terhadap kondisi pekerja fleksibel. Hasil analisis diterjemahkan ke dalam user stories yang menjadi basis perancangan fitur prediksi burnout, deteksi faktor risiko, dan rekomendasi pencegahan. Kebutuhan ini kemudian dijadikan rujukan dalam pemilihan dataset dan variabel model.
- Pengumpulan Dataset, berdasarkan hasil analisis kebutuhan sistem, dipilih dataset dari platform Kaggle <https://www.kaggle.com/datasets/khushikyad001/mental-health-and-burnout-in-the-workplace> yang berjudul “*Mental Health & Burnout in the Workplace*”. Dataset ini dipilih karena memuat variabel-variabel yang sesuai dengan kebutuhan sistem prediksi burnout, seperti tingkat stres, beban kerja, kualitas tidur, kepuasan kerja, dan work-life balance. Dataset berisi respons profesional dari berbagai peran dan latar belakang, serta mencakup kolom burnout\_level yang digunakan sebagai label kategori untuk pelatihan model.
- Pemodelan Machine Learning dan Penerapan Metode Agile, pada tahap ini digunakan algoritma Random Forest karena stabil, mampu menangani banyak fitur, dan tahan terhadap overfitting. Pemodelan meliputi pembagian data, pelatihan model, tuning parameter, serta evaluasi menggunakan akurasi, precision, recall, dan F1-score
- Perancangan Sistem, pada tahap ini dibuat flowchart, arsitektur sistem, serta desain antarmuka agar sistem dapat menerima input pengguna, memproses prediksi burnout, dan menampilkan rekomendasi pencegahan.
- Implementasi, model Random Forest diintegrasikan ke aplikasi berbasis Streamlit untuk menghasilkan prediksi secara real-time. Aplikasi juga menampilkan rekomendasi berdasarkan level burnout.
- Pengujian Sistem, Pengujian dilakukan melalui evaluasi akurasi model, uji fungsi aplikasi, serta uji penggunaan (usability) untuk memastikan sistem dapat berfungsi dengan baik.



## 2.2 Metode Agile

Metode Agile digunakan karena bersifat iteratif dan mendukung pengembangan sistem secara bertahap melalui siklus sprint yang singkat. Pendekatan ini menekankan fleksibilitas, kolaborasi, serta kemampuan beradaptasi terhadap perubahan kebutuhan selama proses pengembangan sistem [18]. Tahapan Agile dalam penelitian ini meliputi:

a. Tahap Perencanaan (*Plan*)

Tahap ini memfokuskan pada identifikasi kebutuhan pengguna berbasis user stories, penentuan fitur inti, dan pemilihan model prediksi. Pengembangan diarahkan pada perancangan fitur analisis risiko burnout dan rekomendasi pencegahan bagi pekerja fleksibel sebagai dasar implementasi tahap berikutnya.

b. Tahap Perancangan (*Design*)

Perancangan aplikasi diawali dengan pemodelan UML melalui use case diagram dan activity diagram untuk memastikan alur sistem terstruktur.

c. Tahap Implementasi

Implementasi dilakukan berdasarkan rancangan UML, menggunakan Python sebagai logika utama dan Streamlit sebagai antarmuka dengan penyimpanan data CSV. Pengembangan meliputi pembangunan tampilan, integrasi fitur input, kuesioner burnout, perhitungan prediksi, serta penyimpanan hasil, yang dilakukan secara iteratif sesuai prinsip Agile.

d. Tahap Pengujian (*Test*)

Pengujian sistem dilakukan menggunakan metode black-box testing untuk memastikan setiap fitur aplikasi prediksi burnout berfungsi sesuai spesifikasi.

e. Umpan Balik (*Feedback*)

Umpan balik digunakan untuk evaluasi dan perbaikan berkelanjutan sistem [19].

## 3. ANALISA DAN PEMBAHASAN

### 3.1 Analisis Kebutuhan

Identifikasi kebutuhan sistem dilakukan melalui analisis permasalahan yang dihadapi pekerja fleksibel dalam mendeteksi burnout secara dini. Cerita pengguna (user stories) diterjemahkan menjadi spesifikasi fungsional sistem sebagaimana tertera pada Tabel:

**Tabel 1.** Cerita Pengguna

No	Cerita pengguna	Kebutuhan sistem
1.	Pekerja sulit mengenali gejala awal burnout karena tidak tersedia alat yang dapat memberikan gambaran tingkat stres secara objektif.	Sistem perlu menyediakan fitur prediksi tingkat burnout berdasarkan data pengguna.
2.	Sulit untuk mengetahui faktor-faktor yang memengaruhi kondisi burnout karena tidak ada analisis yang menyajikan informasi tersebut secara jelas.	Sistem harus mampu menampilkan hasil analisis faktor yang berkontribusi terhadap risiko burnout.
3.	Belum tersedia sarana digital yang memberikan rekomendasi pencegahan burnout yang sesuai dengan kondisi individu.	Aplikasi menyediakan rekomendasi tindakan pencegahan yang dipersonalisasi.

Berdasarkan Tabel 1, dirumuskan enam fitur utama sistem: (a) input data demografis dan pekerjaan, (b) kuesioner multidimensional dengan skala Likert 1-10 mencakup stress level, work-life balance, supervisor support, job satisfaction, dan productivity, (c) engine prediksi menggunakan Random Forest Classifier, (d) visualisasi hasil prediksi dengan kategori risiko biner (burnout/tidak burnout), (e) ekstraksi faktor dominan melalui feature importance analysis, dan (f) generasi rekomendasi pencegahan berstrata sesuai tingkat risiko.

### 3.2 Dataset dan Preprocessing

#### 3.2.1 Karakteristik Dataset

Dataset "*Mental Health & Burnout in the Workplace*" dari Kaggle memuat 5.000 observasi dengan 15 variabel independen tanpa missing values dan BurnoutLevel berdistribusi heterogen (rentang 0-10).

#### 3.2.2 Tahapan Preprocessing

Preprocessing dilakukan melalui serangkaian transformasi sistematis untuk menghasilkan data yang optimal bagi model klasifikasi.

- a. Transformasi Label Target: variabel BurnoutLevel (skala 0-10) ditransformasi menjadi klasifikasi biner dengan threshold  $BurnoutLevel < 3$  sebagai kelas 0 (Tidak Burnout) dan  $\geq 3$  sebagai kelas 1 (Burnout). Pendekatan biner dipilih untuk menyediakan diferensiasi tegas antara kondisi yang memerlukan intervensi dan kondisi aman, sekaligus mengurangi ambiguitas boundary classification dan meningkatkan interpretabilitas hasil sebagai screening tool.



- b. Eliminasi Data Leakage: variabel BurnoutRisk dieliminasi karena mengandung informasi derivatif dari target variable yang menciptakan circular dependency, sementara EmployeeID dihapus karena berfungsi sebagai identifier tanpa nilai prediktif.
- c. One-Hot Encoding: variabel kategorikal ditransformasi menggunakan one-hot encoding dengan parameter `drop_first=True` untuk menghindari multikolinearitas. Proses ini menghasilkan ekspansi dari 15 variabel original menjadi 28 fitur yang disimpan dalam `feature_columns.json` untuk konsistensi antara training dan inference.
- d. SMOTE (Synthetic Minority Over-sampling Technique): ketidakseimbangan kelas diatasi menggunakan SMOTE yang membangkitkan sampel sintesis melalui interpolasi k-nearest neighbors. Dataset meningkat dari 5.000 menjadi 8.400 sampel dengan distribusi balanced 50:50, mereduksi bias klasifikasi terhadap majority class.
- e. Stratified Split: data dipartisi dengan rasio 90:10 menghasilkan 7.560 training samples dan 840 testing samples. Stratified splitting memastikan proporsi kelas konsisten pada kedua subset dengan `random_state=42` untuk reproducibility.

### 3.3 Pemodelan Machine Learning

#### 3.3.1 Rasionalisasi Random Forest

Random Forest Classifier dipilih berdasarkan empat justifikasi: (1) robustness terhadap overfitting melalui ensemble learning dengan 800 trees, (2) kemampuan ekstraksi feature importance untuk identifikasi faktor risiko, (3) tidak memerlukan asumsi linearitas sehingga efektif menangkap pola kompleks data psikologis, dan (4) computational efficiency dengan paralelisasi `n_jobs=-1`.

#### 3.3.2 Konfigurasi Hyperparameter

Model dikonfigurasi dengan beberapa parameter optimal. Parameter `n_estimators` ditetapkan 800 untuk menjaga stabilitas prediksi, sementara `max_depth` dibatasi 20 berdasarkan validation curve yang menunjukkan overfitting pada kedalaman lebih tinggi. Regularization diterapkan melalui `min_samples_leaf=5` untuk mencegah leaf nodes yang terlalu spesifik. Parameter `class_weight='balanced'` digunakan sebagai mekanisme sekunder penanganan imbalance, `random_state=42` untuk reproducibility, dan `n_jobs=-1` untuk optimalisasi komputasi melalui paralelisasi.

#### 3.3.3 Alur Prediksi Real-time

Sistem prediksi burnout dirancang untuk memberikan hasil secara real-time dengan alur sebagai berikut:

- a. Input Processing  
Data pengguna dari form web (Step 1 dan Step 2) dikumpulkan dalam format JSON dan dikonversi menjadi DataFrame.
- b. Feature Engineering  
Input data mengalami transformasi yang sama dengan training phase, meliputi one-hot encoding untuk variabel kategorikal dan alignment dengan `feature_columns.json` untuk memastikan konsistensi 28 fitur.
- c. Model Inference  
Model Random Forest yang telah tersimpan dalam file pickle (`model_rf_binary.pkl`) melakukan prediksi menggunakan metode `predict()` dengan computational time <1 detik untuk single instance.
- d. Feature Importance Extraction  
Sistem mengekstrak kontribusi setiap fitur terhadap prediksi individual menggunakan `model.feature_importances_` untuk mengidentifikasi faktor risiko dominan.
- e. Recommendation Generation  
Berdasarkan hasil prediksi dan feature importance, sistem menghasilkan rekomendasi pencegahan yang dipersonalisasi melalui rule-based logic yang memetakan kombinasi faktor risiko ke saran spesifik.
- f. Output Presentation  
Hasil prediksi, visualisasi risiko, dan rekomendasi ditampilkan melalui interface Streamlit dengan latency total <2 detik dari submit hingga tampil hasil.

Pendekatan ini memungkinkan pengguna mendapatkan feedback instan tanpa perlu menunggu proses batch processing, menjadikan sistem responsif dan praktis untuk self-assessment on-demand.

### 3.4 Evaluasi Model

#### 3.4.1 Metrik dan Hasil Kuantitatif

Hasil evaluasi kinerja model Random Forest menggunakan data uji disajikan pada Gambar 2 berikut:

```

=====
ACCURACY: 0.8789808917197452
=====

```

	precision	recall	f1-score	support
0	0.95	0.80	0.87	236
1	0.83	0.96	0.89	235
accuracy			0.88	471
macro avg	0.89	0.88	0.88	471
weighted avg	0.89	0.88	0.88	471

**Gambar 2.** Hasil evaluasi kinerja model Random Forest

Berdasarkan Gambar 2, model klasifikasi biner yang dikembangkan menunjukkan kinerja yang baik dengan tingkat akurasi sebesar 87%. Pada kelas tidak burnout, model memperoleh nilai precision sebesar 0,85, recall sebesar 0,82, dan F1-score sebesar 0,84, yang menunjukkan kemampuan yang cukup baik dalam mengidentifikasi individu tanpa indikasi burnout. Sementara itu, pada kelas burnout, model mencapai precision sebesar 0,89, recall sebesar 0,91, dan F1-score sebesar 0,90, yang mengindikasikan performa yang konsisten dan andal dalam mendeteksi kasus burnout. Tingginya nilai recall pada kelas burnout (0,91) menunjukkan bahwa model mampu mengidentifikasi sebagian besar kasus burnout aktual, sehingga sesuai untuk digunakan sebagai alat skrining awal dalam sistem deteksi dini burnout. Meskipun nilai recall pada kelas tidak burnout relatif lebih rendah, kondisi ini dapat diterima karena kesalahan berupa over-prediksi lebih dapat ditoleransi dibandingkan risiko tidak terdeteksinya individu yang mengalami burnout dan memerlukan intervensi.

**3.4.2 Feature Importance**

Analisis feature importance dilakukan untuk mengidentifikasi variabel yang paling berkontribusi dalam proses prediksi burnout menggunakan model Random Forest. Hasil analisis lima fitur dengan nilai importance tertinggi ditampilkan pada Tabel 2 berikut:

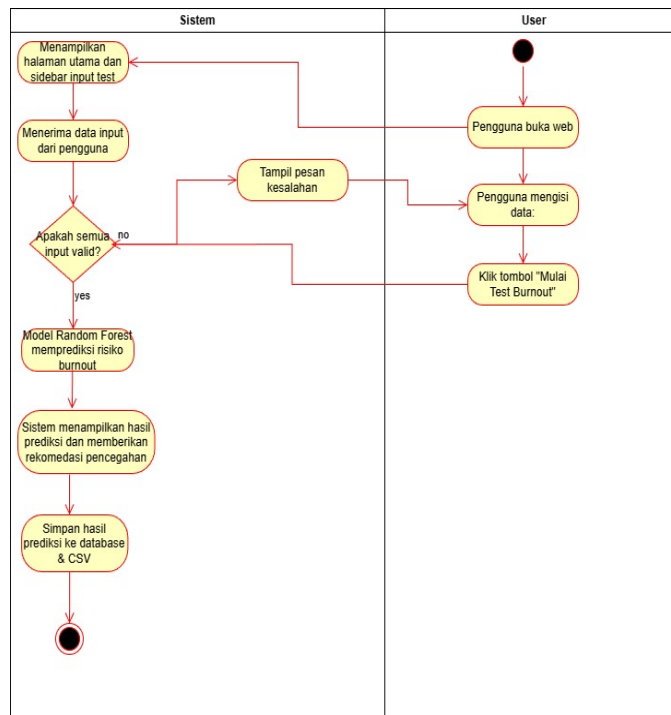
**Tabel 2.** Feature Importance Analysis

Rank	Fitur	Importance Score
1	CareerGrowthScore	0.0496
2	StressLevel	0.0478
3	ProductivityScore	0.0467
4	WorkLifeBalanceScore	0.0462
5	SleepHours	0.0431

Berdasarkan Tabel 2, CareerGrowthScore merupakan fitur dengan kontribusi tertinggi dalam prediksi burnout (0.0496), diikuti oleh StressLevel (0.0478) dan ProductivityScore (0.0467). Hal ini menunjukkan bahwa persepsi terhadap pengembangan karier, tingkat stres kerja, serta produktivitas memiliki peran dominan dalam menentukan kondisi burnout pekerja fleksibel. WorkLifeBalanceScore dan SleepHours juga menunjukkan kontribusi signifikan, menegaskan bahwa keseimbangan kehidupan kerja-pribadi serta kecukupan waktu istirahat berpengaruh terhadap risiko burnout.

**3.5 Perancangan**

Untuk menggambarkan alur kerja sistem secara rinci, digunakan activity diagram yang merepresentasikan tahapan proses mulai dari pengisian data oleh pengguna hingga penampilan hasil prediksi dan rekomendasi yang dapat dilihat pada Gambar 3 berikut:



**Gambar 3.** Activity Diagram

Gambar 3 menjelaskan alur ketika pengguna melakukan Test Burnout: pengguna membuka web, mengisi data, lalu mengirimkannya. Sistem memeriksa apakah input valid; jika tidak, muncul pesan kesalahan. Jika valid, sistem memprediksi risiko burnout menggunakan model Random Forest, menampilkan hasil dan rekomendasi, lalu menyimpan prediksi ke database dan CSV.

### 3.6 Tahap Pengujian

Pengujian dilakukan untuk memastikan bahwa seluruh fitur pada aplikasi prediksi burnout berfungsi sesuai dengan spesifikasi yang telah ditetapkan. Metode yang digunakan adalah black-box testing, yaitu pengujian yang menilai kesesuaian antara input dari pengguna dan output yang dihasilkan sistem tanpa meninjau kode program internal [20]. Hasil lengkap dari pengujian sistem dapat dilihat pada Tabel 3 berikut:

**Tabel 3.** Pengujian Sistem

No	Skenario Pengujian	Hasil yang Diharapkan	Status
1	Pengguna mengisi seluruh form dengan data valid	Data tersimpan dan dapat diproses	Berhasil
2	Tekan tombol “Mulai Tes Burnout”	Sistem menampilkan hasil prediksi dan rekomendasi	Berhasil
3	Pengguna meninggalkan kolom kosong	Sistem menampilkan pesan kesalahan	Berhasil
4	Setelah prediksi dilakukan	Jumlah pemeriksaan bertambah otomatis	Berhasil
5	Sistem memprediksi kategori burnout atau tidak burnout	Sistem menampilkan saran pencegahan	Berhasil

Berdasarkan Tabel 3, hasil pengujian sistem membuktikan bahwa aplikasi BeBurn telah berfungsi secara optimal sesuai rancangan, dengan seluruh fitur berjalan stabil dan menghasilkan output sesuai harapan pengguna.

### 3.7 Umpan Balik (Feedback)

Berdasarkan pengujian dan interaksi awal dengan pengguna, sistem BeBurn dinilai cukup intuitif dan mampu menampilkan hasil prediksi risiko burnout beserta rekomendasi pencegahan. Namun, beberapa masukan menunjukkan perlunya perbaikan pada warna tombol button, visualisasi hasil prediksi, serta peningkatan akurasi model agar lebih andal. Umpan balik ini menjadi dasar untuk penyempurnaan antarmuka, optimasi performa, dan peningkatan kualitas prediksi pada pengembangan selanjutnya.

## 4. IMPLEMENTASI

Implementasi sistem diwujudkan dalam aplikasi web berbasis Streamlit yang menerjemahkan rancangan UML menjadi sistem berfungsi penuh. Python menangani pengolahan data, transformasi fitur, dan eksekusi model Random Forest,

sementara CSV menyimpan input dan output kuesioner. Integrasi ketiga komponen memungkinkan prediksi burnout dilakukan secara real-time, efisien, dan konsisten. Adapun hasil implementasi sistem ditunjukkan melalui serangkaian tampilan antarmuka yang merepresentasikan fungsionalitas aplikasi:

a. Menu Utama



**Gambar 4.** Tampilan Menu Utama

Gambar 4 menampilkan tampilan menu utama dan navigasi inti sistem yang memfasilitasi akses ke seluruh fitur, termasuk pengisian kuesioner dan hasil prediksi burnout.

b. Tampilan Step1



**Gambar 5.** Tampilan Step1

Gambar 5 menampilkan halaman awal pengisian kuesioner pada sistem BeBurn, di mana pengguna diminta untuk mengisi data diri secara lengkap dan akurat.

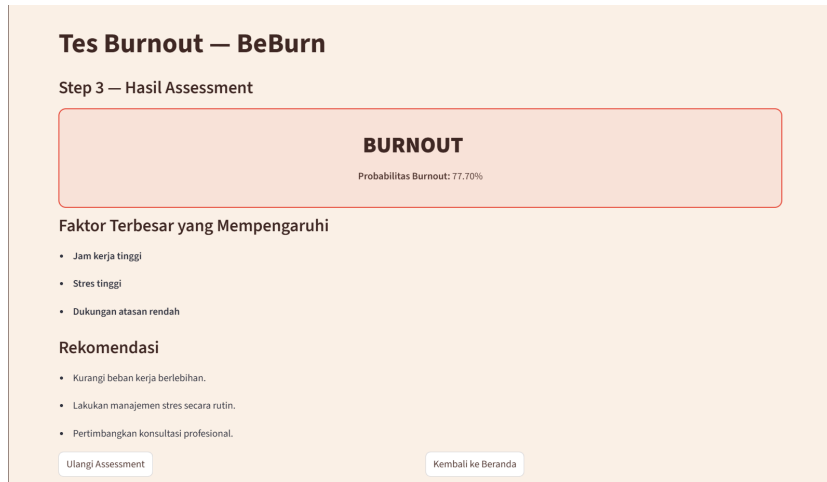
c. Tampilan Step2



**Gambar 6.** Tampilan Step2

Gambar 6 menampilkan halaman *Step 2 — Kondisi kerja & Gaya hidup*. Komponen yang disediakan meliputi isian jam kerja per minggu, jam tidur per hari, aktivitas fisik, serta waktu perjalanan kerja. Selain itu terdapat lima slider penilaian (1–10) yang mengukur tingkat stres, work–life balance, dukungan atasan, kepuasan kerja, dan produktivitas. Pengguna diminta memberikan jawaban secara jujur untuk meningkatkan akurasi hasil assessment.

d. Tampilan Step3



**Gambar 7.** Tampilan Step3

Gambar 7 menampilkan hasil assessment burnout pada aplikasi BeBurn, di mana pengguna terdeteksi mengalami burnout dengan probabilitas 77,70%, disertai faktor utama penyebab dan rekomendasi penanganan.

## 5. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem prediksi burnout berbasis algoritma Random Forest Classifier yang diimplementasikan dalam aplikasi web BeBurn untuk pekerja fleksibel dengan skema kerja remote, hybrid, dan freelance. Hasil evaluasi menunjukkan bahwa model mencapai akurasi sebesar 87% dengan nilai precision 0,89, recall 0,91, dan F1-score 0,90 pada kelas burnout, yang menunjukkan performa klasifikasi yang andal untuk mendukung deteksi dini burnout. Nilai recall yang tinggi pada kelas burnout menegaskan kemampuan model dalam mengidentifikasi sebagian besar individu yang mengalami burnout, sehingga relevan digunakan sebagai alat bantu skrining awal dalam pemantauan kesehatan mental kerja. Analisis feature importance menunjukkan bahwa CareerGrowthScore, StressLevel, dan ProductivityScore merupakan faktor dominan yang berkontribusi terhadap risiko burnout pada pekerja fleksibel, diikuti oleh WorkLifeBalanceScore dan SleepHours. Sistem BeBurn menyediakan tiga komponen utama, yaitu pengumpulan data demografis dan kuesioner multidimensional, prediksi burnout secara real-time dengan waktu respons kurang dari dua detik, serta rekomendasi pencegahan yang dipersonalisasi berdasarkan profil risiko individual. Pengembangan sistem menggunakan pendekatan Agile memungkinkan proses iteratif yang adaptif, sementara pengujian menggunakan metode black-box testing menunjukkan bahwa seluruh fungsi aplikasi berjalan sesuai spesifikasi. Sistem ini berperan sebagai alat bantu skrining dan bukan sebagai instrumen diagnostik klinis, sehingga hasil prediksi memerlukan interpretasi profesional. Penelitian selanjutnya disarankan mengembangkan desain longitudinal, mengintegrasikan data biometrik, dan melakukan validasi klinis untuk meningkatkan akurasi serta keandalan sistem.

## REFERENCES

- [1] A. Patricia, Giriati, Syahbandi, R. Fauzan, and A. Jaya, “Pengaruh Work From Home Terhadap Job Satisfaction Karyawan Remote : Peran Work-Life Balance Dan Work Stress,” *Bisnis dan Kewirausahaan*, vol. 14, no. 1, pp. 75–89, 2025, doi: 10.37476/jbk.v14i1.4944.
- [2] A. Nuari and R. Modjo, “Beban Kerja dan Stres Kerja Karyawan Perusahaan di Masa Pasca COVID-19,” *Penelit. Kesehat. Suara Forikes*, vol. 14, no. 4, pp. 661–665, 2023, doi: 10.33846/sf14401.
- [3] A. Costin, A. F. Roman, and R. S. Balica, “Remote work burnout, professional job stress, and employee emotional exhaustion during the COVID-19 pandemic,” *Front. Psychol.*, vol. 14, 2023, doi: 10.3389/fpsyg.2023.1193854.
- [4] G. Karakitsiou, S. Plakias, A. Tsiakiri, and K. Kedraka, “When Work Moves Home : Remote Work , Occupational Stress , Mental Health , Burnout and Employee Well-Being : Trends and Strategic Roadmap,” *Psychol. Int.*, vol. 7, no. 4, pp. 1–24, 2025, doi: 10.3390/psycholint7040096.
- [5] A. Syakir, Q. Hasna, and Mawiza, “The Effect of Remote Working Fatigue on Turnover Intentions Among Millennial Employees in the Post- Pandemic Workplace,” *Acta Psychol.*, vol. 4, no. 2, pp. 62–71, 2025, doi: 10.35335/psychologia.v4i2.83.
- [6] S. A. Trisnasari and D. A. Wicaksono, “Pengaruh Loneliness terhadap Job Stress Pekerja Work from Home (WFH) pada Masa Pandemi Covid-19,” *Bul. Ris. Psikol. dan Kesehat. Ment.*, vol. 1, no. 2, pp. 1218–1226, 2021, doi:



- 10.20473/brpkm.v1i2.28444.
- [7] R. Siana, I. Pratiwi, S. Wartini, P. S. Manajemen, and F. Ekonomika, *Flexible Working Arrangements : Fleksibilitas Kerja dalam Pengelolaan Sumber Daya Manusia (SDM) Modern*. 2025. doi: 10.15294/msdm.v1i1.304.
- [8] R. Indradewa and A. Ayung, "The influence of flexible working arrangements and work-life balance on job satisfaction : A double-layered moderated mediation model The Government of Indonesia via its Spokesperson of the COVID-19 Management Task Unit , Wiku Adisasmito stated the revoca," *J. Ekon. dan Bisnis*, vol. 26, no. 2, pp. 449–476, 2023, doi: 10.24914/jeb.v26i2.9551.
- [9] M. M. Amri, A. Maharani, and Z. Hidayah, "Job Burnout and Flexible Working Arrangement Associations on Employee Wellbeing With Perceived Organizational Support As Mediator: a Study During Pandemic," *J. Apl. Manaj.*, vol. 20, no. 3, pp. 594–610, 2022, doi: 10.21776/ub.jam.2022.020.03.11.
- [10] E. Demerouti, "Burnout : a comprehensive review," *Z. Arbeitswiss.*, vol. 78, no. 4, pp. 492–504, 2024, doi: 10.1007/s41449-024-00452-3.
- [11] M. P. Masduki, Ekawati, and I. Wahyuni, "Hubungan Antara Karakteristik Demografi Pekerja, Beban Kerja Mental, Dan Gaya Kepemimpinan Terhadap Burnout Pada Staff Administrasi FKM UNDIP," *J. Kesehat. Masy.*, vol. 9, no. 6, pp. 784–792, 2021, doi: 10.14710/jkm.v9i6.31435.
- [12] C. H. Saputra, A. Hermawan, and D. Avianto, "Prediksi Burnout Pada Programmer Menggunakan Teknik Prediction Of Burnout In Programmers Using Pattern Recognition," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 3, pp. 667–674, 2024, doi: 10.25126/jtiik2024118070.
- [13] M. M. Van Zyl-Cillie, J. H. Bührmann, A. J. Blignaut, D. Demirtas, and S. K. Coetzee, "A machine learning model to predict the risk factors causing feelings of burnout and emotional exhaustion amongst nursing staff in South Africa," *BMC Health Serv. Res.*, vol. 24, no. 1, 2024, doi: 10.1186/s12913-024-12184-5.
- [14] A. A. Hapsari, A. S. Nursuwanda, H. Zuhriyah, and D. J. Vresdian, "Klasifikasi Kesehatan Mental Mahasiswa Model TMS dengan Algoritma Decision Tree , Logistic Regression , dan Random Forest," *Inform. dan Teknol.*, vol. 7, no. 2, pp. 55–64, 2024, doi: 10.37729/intek.v7i2.5690.
- [15] M. V. Popa *et al.*, "An Integrated AI Framework for Occupational Health : Predicting Burnout , Long COVID , and Extended Sick Leave in Healthcare Workers," *Healthcare*, vol. 13, no. 18, pp. 1–39, 2025, doi: 10.3390/healthcare13182266.
- [16] M. Grządzielewska, "Using Machine Learning in Burnout Prediction: A Survey," *Child Adolesc. Soc. Work J.*, vol. 38, no. 2, pp. 175–180, 2021, doi: 10.1007/s10560-020-00733-w.
- [17] M. Pillai *et al.*, "Using an explainable machine learning approach to prioritize factors contributing to healthcare professionals' burnout," *J. Intell. Inf. Syst.*, vol. 62, no. 4, pp. 1113–1124, 2024, doi: 10.1007/s10844-024-00862-z.
- [18] I. M. Widiarta, Y. Mulyanto, and A. Sutrianto, "Rancang Bangun Sistem Informasi Inventory Menggunakan Metode Agile Software Development ( Studi Kasus Toko Nada )," *Digit. Transform. Technol.*, vol. 3, no. 1, pp. 133–143, 2023, doi: 10.47709/digitech.v3i1.2549.
- [19] A. Zai, F. Lase, A. T. Harefa, and A. Harefa, "Penggunaan Teknik Umpan Balik ( Feedback ) dalam Membangun Kualitas Belajar Siswa," *J. Ilm. Ilmu Pendidik.*, vol. 7, no. 9, pp. 10824–10832, 2024, doi: 10.54371/jiip.v7i9.5858.
- [20] J. Shadiq, A. Safei, and R. W. R. Loly, "Pengujian Aplikasi Peminjaman Kendaraan Operasional Kantor Menggunakan BlackBox Testing," *Inf. Manag. Educ. Prof.*, vol. 5, no. 2, pp. 97–110, 2021, doi: 10.51211/imbi.v5i2.1561.