

Classification and Interpretability of Employee Burnout Using Linear Discriminant Analysis

Dwi Robiul Rochmawati^{1*}, Muhammad Al Adib², Diyo Mollana Fazri³, Bill Raj⁴, Romi Antoni⁵,
Rahmad Santoso⁶, Wahyu Saptha Negro⁷

^{1,2,3,4,5,6,7}Teknik dan Ilmu Komputer, Ilmu Komputer, Universitas Potensi Utama, Medan, Indonesia

Email: ¹dwirobiul@gmail.com*, ²dibsowden@gmail.com, ³diyomollanafazri@gmail.com, ⁴denilsdu10@gmail.com,

⁵romi04antoni@gmail.com, ⁶rhmd.santoso290992@gmail.com, ⁷wahyusaptha1707@gmail.com

(* Email Corresponding Author: dwirobiul@gmail.com)

Received: 24 Januari 2026 | Revision: 25 Januari 2026 | Accepted: 26 Januari 2026

Abstrak

Employee burnout merupakan permasalahan serius dalam organisasi modern karena berdampak langsung pada kesejahteraan psikologis karyawan, produktivitas kerja, serta keberlanjutan kinerja organisasi. Proses identifikasi burnout di banyak organisasi masih bersifat subjektif dan kurang terintegrasi dengan pendekatan analitik yang transparan. Penelitian ini bertujuan untuk mengembangkan model klasifikasi risiko burnout karyawan yang tidak hanya memiliki tingkat akurasi tinggi, tetapi juga mudah diinterpretasikan oleh praktisi non-teknis. Metode Linear Discriminant Analysis (LDA) dipilih karena kemampuannya dalam memisahkan kelas secara optimal sekaligus menyediakan koefisien diskriminan yang dapat digunakan untuk analisis faktor dominan. Dataset yang digunakan merupakan data sekunder Mental Health in Workplace Survey dengan 3.000 data karyawan dan 15 variabel terkait kondisi kerja, faktor psikososial, serta karakteristik individu. Model dilatih menggunakan 80% data dan diuji pada 20% data sisanya. Hasil pengujian menunjukkan bahwa model LDA mencapai akurasi sebesar 96,17%, dengan nilai recall 100%, precision 89,50%, F1-score 94,46%, serta AUC sebesar 0,9988. Analisis interpretabilitas menunjukkan bahwa tingkat burnout individu, peran jabatan, serta faktor keseimbangan kerja-hidup dan pengembangan karier merupakan variabel yang paling berpengaruh terhadap klasifikasi risiko burnout. Temuan ini menegaskan bahwa LDA merupakan pendekatan yang efektif dan interpretable untuk mendukung deteksi dini burnout serta perancangan intervensi berbasis data di lingkungan kerja.

Kata Kunci: Employee Burnout, Linear Discriminant Analysis, Machine Learning, Interpretabilitas Model, Kesehatan Mental Kerja

Abstract

Employee burnout has become a critical challenge in modern organizations due to its negative impact on employees' mental well-being, work performance, and organizational sustainability. In many workplaces, burnout identification still relies on subjective assessments and retrospective surveys, limiting the effectiveness of early intervention strategies. This study aims to develop an employee burnout risk classification model that achieves high predictive performance while maintaining strong interpretability. Linear Discriminant Analysis (LDA) is employed as the primary method because of its ability to separate classes optimally and provide explicit discriminant coefficients for explanatory analysis. The study utilizes a secondary dataset from the Mental Health in Workplace Survey, consisting of 3,000 employee records and 15 variables related to job characteristics, psychosocial factors, and individual conditions. The dataset is divided into training and testing sets with an 80:20 ratio. Experimental results show that the LDA model achieves an accuracy of 96.17%, with a precision of 89.50%, recall of 100%, F1-score of 94.46%, and an AUC value of 0.9988, indicating excellent classification capability. Further analysis of discriminant coefficients reveals that individual burnout indicators, job roles, work-life balance, and career growth opportunities are the most influential factors in determining burnout risk. These findings demonstrate that LDA offers an effective and interpretable approach for early burnout detection and supports evidence-based decision-making for human resource management.

Keywords: employee burnout, linear discriminant analysis, machine learning, model interpretability, workplace mental health

1. PENDAHULUAN

Fenomena *employee burnout* semakin mendapat perhatian sebagai masalah serius dalam organisasi modern karena berdampak langsung pada kesehatan mental karyawan, penurunan kinerja, meningkatnya niat pindah kerja, hingga *turnover* aktual [1], [2], [3]. *Burnout* ditandai oleh kelelahan emosional dan fisik yang berkepanjangan, sinisme terhadap pekerjaan, serta menurunnya efikasi profesional, yang pada akhirnya mereduksi produktivitas dan kualitas layanan [3], [4]. Berbagai studi menunjukkan bahwa prevalensi *burnout* meningkat di beragam profesi, mulai dari tenaga kesehatan, guru, hingga pekerja sektor jasa dan manufaktur [3], [5], [6]. Di banyak organisasi, deteksi *burnout* masih mengandalkan kuesioner manual dan penilaian subjektif, yang bersifat retrospektif, kurang real-time, dan sering kali tidak terintegrasi dengan sistem pengambilan keputusan berbasis data [7], [8]. Kondisi ini menyulitkan manajemen untuk mengidentifikasi karyawan berisiko secara dini dan merancang intervensi pencegahan yang terarah.

Perkembangan *machine learning* membuka peluang untuk mengembangkan model prediksi *burnout* berbasis data besar yang mampu mengungkap pola laten antara faktor pekerjaan, karakteristik individu, dan gejala psikologis [5], [8]. Penelitian terkini menunjukkan bahwa burnout karyawan dapat diprediksi cukup akurat dengan berbagai algoritma machine learning seperti Random Forest, Logistic Regression, SVM, Gradient Boosting, hingga XGBoost, baik pada konteks attrition, tenaga kesehatan, maupun guru [1], [3], [8], [9], [10], [11]. Namun, sebagian besar studi tersebut

berfokus pada kinerja prediktif dan pemilihan algoritma terbaik, sementara aspek interpretabilitas model—siapa yang burnout, karena faktor apa, dan bagaimana pola fitur membentuk keputusan model—masih relatif kurang dieksplorasi secara sistematis, khususnya pada konteks karyawan non-kesehatan [1], [3], [8], [9], [11]. Di sisi lain, literatur umum tentang burnout dan ML menekankan bahwa metode yang dipilih harus disesuaikan dengan tujuan (prediksi vs pemahaman teoretis), dan bahwa ML justru berpotensi membangun model teoritis baru tentang burnout dan mendukung intervensi berbasis data [8]. Studi yang menggunakan Linear Discriminant Analysis (LDA) dengan Maslach Burnout Inventory memang melaporkan akurasi sangat tinggi, tetapi masih menekankan performa klasifikasi dan belum mengelaborasi penuh potensi LDA sebagai model yang secara inheren dapat diinterpretasi untuk memetakan kontribusi dimensi burnout dan variabel kerja terhadap kelas burnout [10]. Selain itu, kajian explainable ML di domain lain menunjukkan kebutuhan mendesak akan model yang seimbang antara akurasi dan transparansi untuk aplikasi di domain sensitif seperti kesehatan mental [12], [13], [14]. Dengan demikian, masih terdapat celah berupa kurangnya penelitian yang secara eksplisit memadukan klasifikasi burnout karyawan dan analisis interpretabilitas berbasis LDA pada data kuesioner/HR, sehingga menghasilkan model yang tidak hanya akurat tetapi juga mudah dipahami oleh praktisi HR dan manajer untuk merancang intervensi yang terarah.

Berdasarkan celah tersebut, penelitian ini menawarkan solusi berupa pengembangan model klasifikasi *employee burnout* menggunakan *linear discriminant analysis* yang menekankan dua aspek utama, yaitu kemampuan klasifikasi dan keterjelasan interpretasi. LDA dipilih karena secara eksplisit membentuk kombinasi linier variabel prediktor yang memaksimalkan pemisahan antar kelas, sehingga koefisien fungsi diskriminan dapat digunakan untuk mengidentifikasi dan menjelaskan variabel mana yang paling berkontribusi terhadap risiko *burnout* [15], [16], [17]. Dengan memanfaatkan data faktor kerja (misalnya beban kerja, dukungan organisasi, *work-life balance*, kondisi kesehatan, dan dukungan psikologis) yang telah terbukti berkaitan dengan *burnout* [6], [18], [19] model diharapkan mampu mengelompokkan karyawan ke dalam kategori tingkat *burnout* secara akurat sekaligus menyediakan dasar penjelasan yang mudah dipahami oleh pemangku kepentingan non-teknis.

Dengan demikian, tujuan utama penelitian berjudul “*Classification and Interpretability of Employee Burnout Using Linear Discriminant Analysis*” adalah: (1) mengembangkan model klasifikasi untuk mengelompokkan karyawan berdasarkan tingkat *burnout* menggunakan LDA; (2) menganalisis faktor-faktor dominan yang memengaruhi klasifikasi *burnout* melalui koefisien fungsi diskriminan yang dihasilkan; dan (3) menyajikan kerangka interpretasi yang dapat digunakan oleh manajemen dan HR untuk merancang strategi pencegahan dan intervensi *burnout* berbasis bukti. Diharapkan hasil penelitian ini memberikan kontribusi akademik berupa model klasifikasi yang akurat dan interpretable, sekaligus manfaat praktis bagi organisasi dalam upaya menjaga kesejahteraan psikologis karyawan, menekan risiko *burnout*, dan meningkatkan keberlanjutan kinerja organisasi.

2. METODOLOGI PENELITIAN

2.1 Jenis dan Pendekatan Penelitian

Penelitian ini menggunakan pendekatan **kuantitatif** dengan metode **klasifikasi berbasis machine learning** untuk mengelompokkan tingkat risiko *employee burnout*. Tujuan utama penelitian adalah membangun model klasifikasi menggunakan **Linear Discriminant Analysis (LDA)** serta menganalisis faktor-faktor dominan yang memengaruhi risiko burnout karyawan secara interpretable.

2.2 Dataset Penelitian

Dataset yang digunakan merupakan dataset sekunder yang diperoleh dari Kaggle berjudul **Mental Health in Workplace Survey Dataset**. Dataset ini terdiri dari **3.000 data karyawan** dengan **25 atribut**, yang menggambarkan kondisi kerja, karakteristik individu, faktor psikososial, serta indikator kesehatan mental di lingkungan kerja.

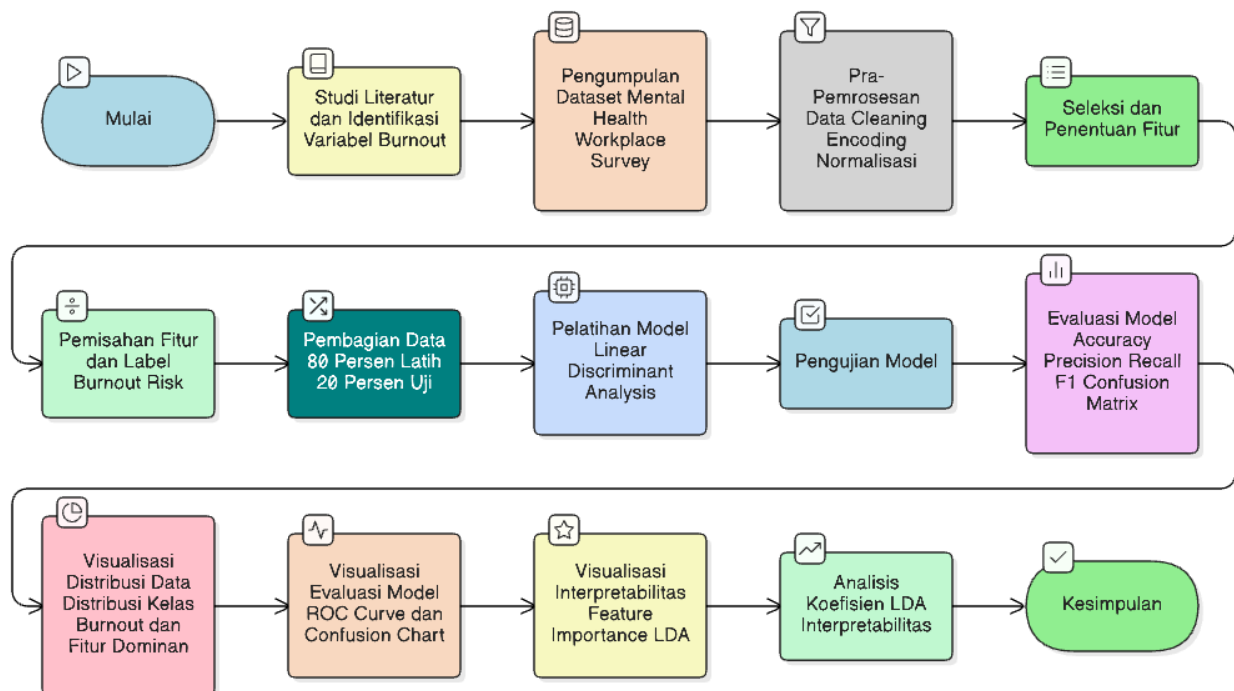
Variabel target dalam penelitian ini adalah **BurnoutRisk**, yang merepresentasikan kategori risiko burnout karyawan (0 = rendah, 1 = tinggi).

Tabel 1. Jenis jenis database

No	Variabel	Keterangan
1	Age	Usia karyawan
2	Gender	Jenis kelamin
3	JobRole	Jabatan
4	Department	Departemen
5	YearsAtCompany	Lama bekerja
6	WorkHoursPerWeek	Jam kerja per minggu
7	RemoteWork	Status kerja jarak jauh
8	JobSatisfaction	Kepuasan kerja

No	Variabel	Keterangan
9	StressLevel	Tingkat stres
10	SleepHours	Jam tidur
11	CommuteTime	Waktu tempuh ke kantor
12	ManagerSupportScore	Dukungan atasan
13	WorkLifeBalanceScore	Keseimbangan kerja-hidup
14	CareerGrowthScore	Peluang pengembangan karier
15	BurnoutRisk	Variabel target

2.3 Tahapan Penelitian



Gambar 1. *Flowchart* Tahapan Penelitian

Tahapan penelitian ini dilakukan sebagai berikut:

a. Studi Literatur

Tahap awal penelitian diawali dengan studi literatur untuk mengidentifikasi konsep burnout, indikator psikososial, serta variabel kerja yang relevan berdasarkan penelitian terdahulu. Hasil studi literatur digunakan sebagai dasar pemilihan variabel penelitian dan perancangan model klasifikasi.

b. Pengumpulan Data

Pengumpulan Dataset Mental Health Workplace Survey. Data diunduh dari Kaggle dan dilakukan verifikasi struktur, tipe data, serta kelengkapan nilai.

c. Pra-pemrosesan Data

Tahap ini meliputi:

1. Penanganan data kosong (missing values),
2. Encoding variabel kategorikal (Gender, JobRole, Department, RemoteWork),
3. Normalisasi data numerik,
4. Pemisahan fitur dan label (*BurnoutRisk*).

d. Pembagian Data

Dataset dibagi menjadi:

- 80% data latih

- 20% data uji

Pembagian dilakukan secara acak untuk memastikan generalisasi model.

e. Penerapan Linear Discriminant Analysis (LDA)

LDA digunakan untuk membangun fungsi diskriminan yang memaksimalkan perbedaan antar kelas burnout (rendah dan tinggi). Model ini tidak hanya melakukan klasifikasi, tetapi juga menghasilkan koefisien yang dapat digunakan untuk menganalisis kontribusi masing-masing variabel.

f. Evaluasi Model

Model dievaluasi menggunakan metrik:

- Accuracy
- Precision
- Recall
- F1-Score
- Confusion Matrix

g. Visualisasi

1. Visualisasi Distribusi Data (Distribusi Kelas Burnout & Fitur Dominan)
2. Visualisasi Evaluasi Model (ROC Curve & Confusion Chart)
3. Visualisasi Interpretabilitas (Feature Importance LDA)

Visualisasi digunakan untuk:

- memverifikasi keseimbangan dan karakteristik data,
- menunjukkan performa model secara visual (ROC, Confusion),
- menampilkan *feature importance* sebagai dasar interpretabilitas.

2.4 Model Linear Discriminant Analysis

LDA membentuk fungsi diskriminan linier sebagai berikut:

$$D(x) = \mathcal{W}_1 x_1 + \mathcal{W}_2 x_2 + \dots + \mathcal{W}_n x_n + \mathcal{C} \quad (1)$$

dimana :

\mathcal{W} adalah bobot variable

x adalah fitur input \mathcal{M}

\mathcal{C} adalah konstanta

Koefisien \mathcal{W} digunakan untuk menentukan faktor dominan penyebab burnout.

2.5 Analisis Interpretabilitas

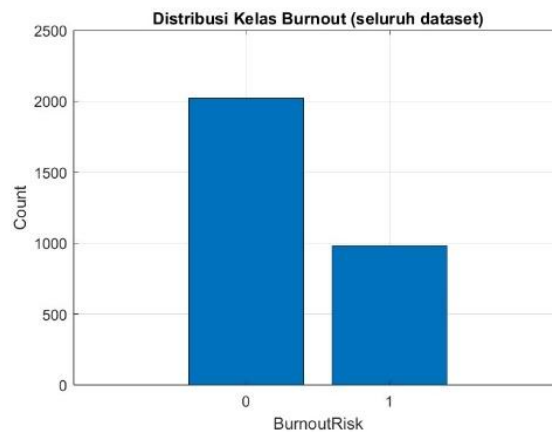
Interpretasi dilakukan dengan menganalisis nilai koefisien LDA. Variabel dengan nilai koefisien terbesar dianggap memiliki pengaruh paling signifikan terhadap risiko burnout, sehingga dapat digunakan sebagai dasar pengambilan keputusan bagi manajemen dalam merancang program pencegahan burnout.

3. HASIL DAN PEMBAHASAN

Bagian ini membahas hasil penerapan Linear Discriminant Analysis (LDA) dalam mengklasifikasikan risiko burnout karyawan, serta interpretasi faktor-faktor yang berkontribusi terhadap keputusan model. Pembahasan disusun secara bertahap, dimulai dari karakteristik data, evaluasi performa model, hingga analisis interpretabilitas berdasarkan koefisien diskriminan.

3.1 Karakteristik Data dan Distribusi Kelas Burnout

Analisis awal dilakukan untuk memahami distribusi kelas burnout pada dataset yang digunakan. Visualisasi distribusi kelas burnout ditampilkan pada Gambar 2.



Gambar 2. Karakteristik Data dan Distribusi Kelas Burnout

Berdasarkan Gambar 2, terlihat bahwa jumlah karyawan dengan kategori BurnoutRisk = 0 (risiko rendah) lebih besar dibandingkan dengan BurnoutRisk = 1 (risiko tinggi). Distribusi ini mencerminkan kondisi empiris di lingkungan kerja, di mana tidak seluruh karyawan berada dalam kondisi burnout tinggi. Meskipun terdapat ketimpangan jumlah antar kelas, proporsinya masih berada dalam batas yang wajar sehingga tidak memerlukan perlakuan khusus seperti penyeimbangan data sintetis.

Distribusi kelas ini menjadi konteks penting dalam interpretasi hasil evaluasi model. Model klasifikasi yang baik tidak hanya mampu mencapai akurasi tinggi pada kelas mayoritas, tetapi juga harus sensitif dalam mendeteksi kelas minoritas, khususnya kelas burnout tinggi yang memiliki implikasi serius bagi kesejahteraan karyawan dan organisasi.

3.2 Hasil Seleksi Fitur dan Kesiapan Data untuk Pemodelan

Top 15 features by MRMR:

Feature	Score
{ 'Department_Engineering' }	32
{ 'StressLevel' }	31
{ 'CareerGrowthScore' }	30
{ 'BurnoutLevel' }	29
{ 'WorkLifeBalanceScore' }	28
{ 'ProductivityScore' }	27
{ 'CommuteTime' }	26
{ 'MentalHealthDaysOff' }	25
{ 'SleepHours' }	24
{ 'Department_HR' }	23
{ 'Department_IT' }	22
{ 'JobSatisfaction' }	21
{ 'TeamSize' }	20
{ 'Department_Marketing' }	19
{ 'PhysicalActivityHrs' }	18

Training samples: 2400, Test samples: 600

Gambar 3. Hasil Seleksi Fitur

Sebelum proses klasifikasi, dilakukan seleksi fitur menggunakan metode Minimum Redundancy Maximum Relevance (MRMR) untuk memastikan bahwa fitur yang digunakan memiliki relevansi tinggi terhadap variabel target dan redundansi yang rendah antar fitur. Hasil seleksi yang ditunjukkan pada Gambar 3 menunjukkan bahwa variabel-variabel psikologis, organisasi, dan lingkungan kerja memiliki kontribusi yang signifikan. Fitur-fitur seperti **BurnoutLevel**, **StressLevel**, **CareerGrowthScore**, **WorkLifeBalanceScore**, serta beberapa atribut departemen dan kondisi kerja terpilih sebagai fitur utama. Hal ini menunjukkan bahwa risiko burnout tidak ditentukan oleh satu faktor tunggal, melainkan merupakan hasil interaksi multidimensional antara kondisi internal karyawan dan lingkungan kerja. Dataset yang telah melalui tahap seleksi fitur ini kemudian digunakan sebagai masukan untuk pelatihan model LDA.

3.3 Evaluasi Kinerja Model LDA

```

Model Evaluation on Test Set:
Accuracy: 0.9617
Precision: 0.8950
Recall: 1.0000
F1-score: 0.9446
Confusion Matrix:

```

	Pred0	Pred1
True0	381	23
True1	0	196

Gambar 4 Karakteristik Data dan Distribusi Kelas Burnout

Model LDA dilatih menggunakan 80% data latih dan diuji pada 20% data uji. Evaluasi performa dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score untuk memberikan gambaran menyeluruh tentang kemampuan klasifikasi model.

Pada gambar 4 tertera bahwa hasil pengujian menunjukkan bahwa model mencapai **akurasi sebesar 96,17%**, yang mengindikasikan tingkat ketepatan klasifikasi yang sangat tinggi. Nilai akurasi ini menunjukkan bahwa sebagian besar data uji berhasil diklasifikasikan dengan benar oleh model.

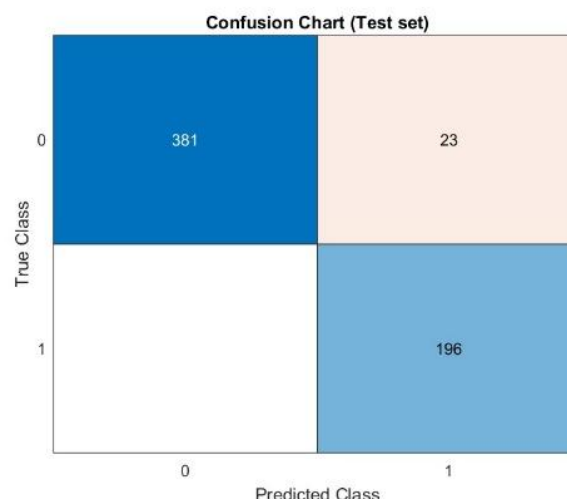
Nilai **precision sebesar 89,50%** mengindikasikan bahwa mayoritas karyawan yang diprediksi memiliki risiko burnout tinggi memang benar berasal dari kelas tersebut. Dengan demikian, tingkat kesalahan berupa prediksi burnout tinggi pada karyawan yang sebenarnya tidak berisiko relatif terbatas.

Sementara itu, **recall sebesar 100%** menunjukkan bahwa seluruh karyawan dengan risiko burnout tinggi pada data uji berhasil teridentifikasi oleh model. Capaian ini sangat penting dalam konteks kesehatan mental dan manajemen sumber daya manusia, karena kegagalan mendeteksi individu yang benar-benar berisiko dapat berdampak serius terhadap produktivitas dan kesejahteraan psikologis.

Keseimbangan antara precision dan recall tercermin pada **F1-score sebesar 94,46%**, yang menunjukkan bahwa model memiliki performa yang konsisten dan andal dalam mendeteksi burnout tanpa menghasilkan terlalu banyak kesalahan klasifikasi.

3.4 Analisis Confusion Matrix

Untuk memahami distribusi hasil prediksi secara lebih rinci, digunakan confusion matrix yang ditampilkan pada **Gambar 3**.



Gambar 5. Analisis Confusion Matrix


Berdasarkan Gambar 5, terdapat 381 data true negative, yaitu karyawan dengan risiko burnout rendah yang berhasil diklasifikasikan secara benar. Selain itu, terdapat 196 data true positive, yang menunjukkan bahwa seluruh karyawan dengan risiko burnout tinggi pada data uji terdeteksi dengan tepat.

Sebanyak 23 data false positive ditemukan, yaitu karyawan dengan risiko rendah yang diprediksi sebagai risiko tinggi. Namun, tidak terdapat false negative, yang berarti tidak ada karyawan dengan risiko burnout tinggi yang luput dari deteksi model.

Dari sudut pandang praktis, kondisi ini sangat menguntungkan. Dalam konteks pencegahan burnout, kesalahan false positive relatif lebih dapat ditoleransi dibandingkan false negative. Memberikan perhatian tambahan kepada karyawan yang sebenarnya tidak berisiko tidak menimbulkan dampak negatif yang signifikan, sementara kegagalan mendeteksi karyawan yang benar-benar burnout berpotensi menimbulkan konsekuensi yang jauh lebih serius.

3.5 Evaluasi Tambahan Menggunakan Kurva ROC

Selain confusion matrix, evaluasi performa model juga dilakukan menggunakan kurva Receiver Operating Characteristic (ROC) yang ditampilkan pada Gambar 4.



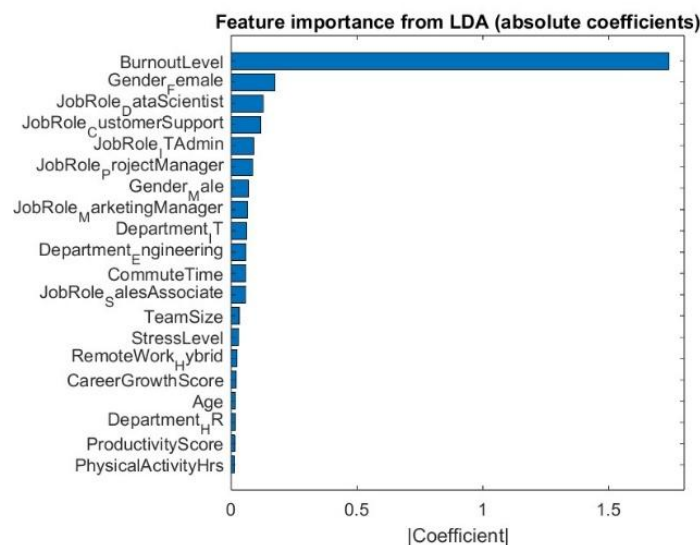
Gambar 6 Kurva ROC Model LDA

Berdasarkan Gambar 6, model menghasilkan nilai Area Under Curve (AUC) sebesar 0,9988, yang mendekati nilai maksimum. Nilai AUC ini menunjukkan bahwa model memiliki kemampuan diskriminatif yang sangat tinggi dalam membedakan karyawan dengan risiko burnout rendah dan tinggi pada berbagai ambang keputusan.

Kurva ROC yang berada dekat dengan sudut kiri atas menunjukkan bahwa model mampu mencapai tingkat sensitivitas dan spesifisitas yang tinggi secara bersamaan. Dengan demikian, performa model tidak hanya optimal pada satu threshold tertentu, tetapi juga stabil ketika digunakan dalam berbagai skenario pengambilan keputusan.

3.6 Analisis Interpretabilitas Berdasarkan Koefisien LDA

Salah satu keunggulan utama LDA adalah kemampuannya untuk diinterpretasikan secara langsung melalui koefisien fungsi diskriminan. Visualisasi kontribusi fitur terhadap model ditampilkan pada Gambar 5.



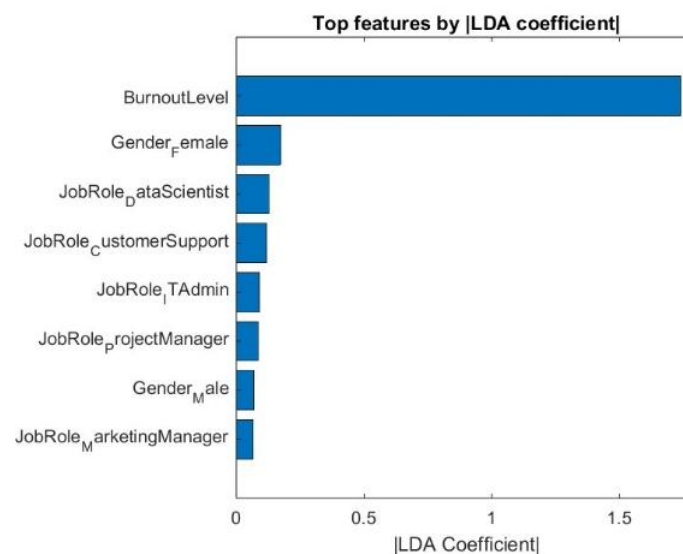
Gambar 7 Analisis Interpretabilitas Berdasarkan Koefisien LDA

Berdasarkan Gambar 7, fitur BurnoutLevel memiliki nilai koefisien absolut paling besar dibandingkan fitur lainnya. Hal ini menunjukkan bahwa variabel tersebut merupakan faktor paling dominan dalam membedakan kelas burnout rendah dan tinggi. Koefisien bernilai positif mengindikasikan bahwa peningkatan BurnoutLevel secara langsung meningkatkan probabilitas karyawan diklasifikasikan ke dalam kelas risiko burnout tinggi.

Fitur-fitur lain seperti JobRole_ProjectManager dan JobRole_MarketingManager juga menunjukkan koefisien positif, meskipun dengan magnitudo yang lebih kecil. Hal ini mengindikasikan bahwa peran jabatan dengan tanggung jawab koordinatif dan tekanan target yang tinggi cenderung berkorelasi dengan peningkatan risiko burnout. Sebaliknya, beberapa fitur seperti StressLevel, CareerGrowthScore, SleepHours, dan PhysicalActivityHrs memiliki koefisien negatif. Arah koefisien ini menunjukkan bahwa kondisi kerja dan gaya hidup yang lebih sehat serta peluang pengembangan karier yang baik berkontribusi dalam menurunkan risiko burnout.

3.7 Ringkasan Fitur Dominan Penyebab Burnout

Untuk memperjelas variabel yang paling berpengaruh, ditampilkan ringkasan fitur dengan nilai koefisien LDA terbesar secara absolut pada Gambar 6.



Gambar 8 Analisis Interpretabilitas Berdasarkan Koefisien LDA

Berdasarkan Gambar 8, dapat disimpulkan bahwa faktor internal terkait tingkat burnout individu tetap menjadi penentu utama, diikuti oleh faktor demografis dan struktural seperti gender dan peran jabatan. Namun demikian, kontribusi faktor-faktor tersebut bersifat komplementer dan tidak berdiri sendiri.

Hasil ini menegaskan bahwa burnout merupakan fenomena multidimensional yang tidak dapat dijelaskan hanya melalui satu variabel tunggal. Oleh karena itu, pendekatan klasifikasi yang mampu menangkap kombinasi faktor psikologis dan lingkungan kerja, seperti LDA, menjadi sangat relevan dalam konteks organisasi modern.

4. KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa Linear Discriminant Analysis (LDA) merupakan pendekatan yang efektif dan relevan dalam mengklasifikasikan risiko burnout karyawan sekaligus memberikan pemahaman yang jelas terhadap faktor-faktor yang mendasari kondisi tersebut. Berdasarkan hasil pengujian, model LDA mampu mencapai performa klasifikasi yang sangat tinggi, yang tercermin dari nilai akurasi, precision, recall, F1-score, serta AUC yang mendekati nilai optimal. Temuan ini mengindikasikan bahwa LDA tidak hanya andal dalam membedakan karyawan dengan risiko burnout rendah dan tinggi, tetapi juga konsisten dalam mendeteksi seluruh individu yang benar-benar berada pada kondisi burnout tinggi, yang merupakan aspek krusial dalam konteks kesehatan mental di lingkungan kerja. Selain keunggulan performa, kontribusi utama penelitian ini terletak pada aspek interpretabilitas model. Analisis koefisien fungsi diskriminan menunjukkan bahwa risiko burnout dipengaruhi oleh kombinasi faktor psikologis, karakteristik pekerjaan, serta kondisi pendukung di tempat kerja. Variabel terkait tingkat burnout individu dan peran jabatan terbukti memiliki kontribusi dominan dalam proses klasifikasi, sementara faktor-faktor seperti keseimbangan kerja-hidup, peluang pengembangan karier, jam tidur, dan aktivitas fisik berperan sebagai faktor protektif yang menurunkan risiko burnout. Hasil ini menegaskan bahwa burnout merupakan fenomena multidimensional yang tidak dapat dijelaskan secara parsial. Secara praktis, temuan penelitian ini memberikan dasar yang kuat bagi manajemen dan praktisi sumber daya manusia untuk memanfaatkan model klasifikasi yang transparan dan berbasis data dalam mendeteksi risiko burnout secara dini. Dengan

pemahaman yang lebih jelas mengenai faktor-faktor penentu burnout, organisasi dapat merancang strategi pencegahan dan intervensi yang lebih terarah, berkelanjutan, serta berorientasi pada peningkatan kesejahteraan karyawan dan kinerja organisasi secara keseluruhan.

REFERENCES

- [1] M. S and J. Krishnan, "Analyzing Employee Attrition Drivers: The Impact of Burnout Through Predictive Models," *Int. J. Sci. Technol.*, Jun. 2025, doi: 10.71097/ijst.v16.i2.6248.
- [2] A. Sajeena, "Employee Burnout Prediction Using Data Sceince," *INTERANTIONAL J. Sci. Res. Eng. Manag.*, Jan. 2025, doi: 10.55041/ijstrem41241.
- [3] G. Fehér *et al.*, "Mental issues, internet addiction and quality of life predict burnout among Hungarian teachers: a machine learning analysis," *BMC Public Health*, vol. 24, Aug. 2024, doi: 10.1186/s12889-024-19797-9.
- [4] Y. Shoman, S. Marca, R. Bianchi, L. Godderis, H. Van Der Molen, and G. Canu, "Psychometric properties of burnout measures: a systematic review," *Epidemiol. Psychiatr. Sci.*, vol. 30, Jan. 2021, doi: 10.1017/s2045796020001134.
- [5] P. Zhernova, Y. Bodyanskiy, B. Yatsenko, and I. Zavgorodnii, "Detection and Prevention of Professional Burnout Using Machine Learning Methods," *2020 IEEE 15th Int. Conf. Adv. Trends Radioelectron. Telecommun. Comput. Eng. TCSET*, pp. 218–221, Feb. 2020, doi: 10.1109/tcset49122.2020.235426.
- [6] C. Thrush, M. Gathright, T. Atkinson, E. Messias, and B. Guise, "Psychometric Properties of the Copenhagen Burnout Inventory in an Academic Healthcare Institution Sample in the U.S.," *Eval. Health Prof.*, vol. 44, pp. 400–405, Jun. 2020, doi: 10.1177/0163278720934165.
- [7] S. Tyagi, A. Tomar, and M. Mohit, "Prediction of Mental Burnout Using Machine Learning," *Int. J. Sci. Res. Eng. Manag.*, Nov. 2025, doi: 10.55041/ijstrem53497.
- [8] M. Grządzielewska, "Using Machine Learning in Burnout Prediction: A Survey," *Child Adolesc. Soc. Work J.*, vol. 38, pp. 175–180, Jan. 2021, doi: 10.1007/s10560-020-00733-w.
- [9] M. Van Zyl-Cillié, J. Bührmann, A. Bliognaut, D. Demirtas, and S. 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, 2024, doi: 10.1186/s12913-024-12184-5.
- [10] A. Hernandez, E. Albina, and R. Perez, "Development of Occupational Burnout Prediction Models Using Machine Learning Techniques and Maslach Burnout Inventory," *2024 IEEE 15th Control Syst. Grad. Res. Colloq. ICSGRC*, pp. 47–51, Aug. 2024, doi: 10.1109/icsgrc62081.2024.10690950.
- [11] S. Hladiholov and O. Mokin, "Comparative Analysis of Machine Learning Models for Predicting Employee Burnout Problem," *Visnyk Vinnytsia Politech. Inst.*, 2023, doi: 10.31649/1997-9266-2023-170-5-25-31.
- [12] A. Alatrany, W. Khan, A. Hussain, H. Kolivand, and D. Al-Jumeily, "An explainable machine learning approach for Alzheimer's disease classification," *Sci. Rep.*, vol. 14, 2024, doi: 10.1038/s41598-024-51985-w.
- [13] T. Kaluarachchi, A. Reis, and S. Nanayakkara, "A Review of Recent Deep Learning Approaches in Human-Centered Machine Learning," *Sensors*, vol. 21, 2021, doi: 10.3390/s21072514.
- [14] J. Van Der Donckt, E. Deprost, N. Vandebussche, M. Rademaker, G. Vandewiele, and S. Van Hoecke, "Do not sleep on traditional machine learning: Simple and interpretable techniques are competitive to deep learning for sleep scoring," *Biomed. Signal Process. Control*, vol. 81, p. 104429, 2022, doi: 10.1016/j.bspc.2022.104429.
- [15] J. Park, J. Ahn, and Y. Jeon, "Sparse functional linear discriminant analysis," *Biometrika*, Nov. 2020, doi: 10.1093/biomet/asaa107.
- [16] H. Zhou, "Linear discriminant analysis," *Nat. Rev. Methods Primer*, vol. 4, Jan. 2020, doi: 10.1038/s43586-024-00357-9.
- [17] J. Wen *et al.*, "Robust Sparse Linear Discriminant Analysis," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 29, pp. 390–403, Feb. 2019, doi: 10.1109/tcsvt.2018.2799214.
- [18] K. Sakakibara, A. Shimazu, H. Toyama, and W. Schaufeli, "Validation of the Japanese Version of the Burnout Assessment Tool," *Front. Psychol.*, vol. 11, Aug. 2020, doi: 10.3389/fpsyg.2020.01819.
- [19] H. Sun, T. Zhang, X. Wang, C. Wang, M. Zhang, and H. Song, "The occupational burnout among medical staff with high workloads after the COVID-19 and its association with anxiety and depression," *Front. Public Health*, vol. 11, Oct. 2023, doi: 10.3389/fpubh.2023.1270634.