

MODEL AI PREDIKSI *BURNOUT* BERBASIS *WORKLOAD* STAF KLINIS

Dola Ramalinda¹, Yudi Darsono², Agung Rachmat Raharja³

¹Universitas Bandung, dolaramalinda@bandungunivesity.ac.id

²Universitas Bandung, yudidarsono@bandungunivesity.ac.id

³Universitas Bandung, agungrachmat@universitasbandung.ac.id

ABSTRAK

Burnout pada tenaga kesehatan merupakan tantangan sistemik yang berdampak pada kualitas layanan dan keselamatan pasien. Beban kerja klinis, pola shift yang intens, serta tuntutan administratif dari penggunaan *Electronic Health Record* (EHR) menjadi faktor yang berpotensi meningkatkan stres kerja. Meskipun data operasional tersedia dalam Sistem Informasi Rumah Sakit (SIRS), pemanfaatannya untuk deteksi dini risiko *burnout* staf masih terbatas. Penelitian ini bertujuan mengembangkan dan mengevaluasi model *supervised machine learning* untuk memprediksi risiko *burnout* staf klinis berdasarkan data perilaku dan beban kerja dari SIRS dan EHR. Penelitian kuantitatif dengan desain prediktif melibatkan 120 staf klinis yang terdiri atas dokter dan perawat. Data primer tingkat *burnout* diperoleh melalui instrumen terstandar, sedangkan data sekunder mencakup aktivitas EHR, jumlah pasien, jam kerja, dan pola shift. Tiga algoritma dibandingkan, yaitu *Logistic Regression*, *Random Forest*, dan *Gradient Boosting*, menggunakan metrik akurasi dan *Area Under the Curve* (AUC). Hasil menunjukkan bahwa perawat dan staf dengan pola kerja shift memiliki proporsi risiko *burnout* sedang hingga tinggi yang lebih besar. Beban kerja, terutama volume pasien dan jam kerja, serta intensitas aktivitas EHR menjadi faktor penting yang berkaitan dengan risiko *burnout*. *Gradient Boosting* menghasilkan kinerja terbaik dengan akurasi 0,87 dan AUC 0,91. Model tersebut berpotensi digunakan sebagai instrumen deteksi dini untuk mendukung redistribusi beban kerja, optimalisasi jadwal shift, dan intervensi preventif berbasis data dalam manajemen SDM rumah sakit.

Kata Kunci : *Burnout*, Staf Klinis, *Machine Learning*, *Electronic Health Record* (EHR)

ABSTRACT

Burnout among healthcare workers is a systemic challenge that affects service quality and patient safety. Clinical workload, intensive shift patterns, and administrative demands associated with the use of Electronic Health Records (EHR) are potential factors contributing to work-related stress. Although operational data are available through Hospital Information Systems (HIS), their use for the early detection of staff burnout risk remains limited. This study aims to develop and evaluate a supervised machine learning model to predict burnout risk among clinical staff based on work behavior and workload data obtained from HIS and EHR. This quantitative study employed a predictive design involving 120 clinical staff members consisting of physicians and nurses. Primary data on burnout levels were obtained using a standardized instrument, while secondary data included EHR activity, patient volume, working hours, and shift patterns. Three algorithms were compared: Logistic Regression, Random Forest, and Gradient Boosting, using accuracy and Area Under the Curve (AUC) as evaluation metrics. The results showed that nurses and staff working in shift-based patterns had a higher proportion of moderate-to-high burnout risk. Workload, particularly patient volume and working hours, as well as the intensity of EHR activity, were important factors associated with burnout risk. Gradient Boosting achieved the best performance, with an accuracy of 0.87 and an AUC of 0.91. The model has the potential to serve as an early detection instrument to support workload redistribution, shift schedule optimization, and data-driven preventive interventions in hospital human resource management.

Keywords: *Burnout, Clinical Staff, Machine Learning, Electronic Health Record (EHR).*

PENDAHULUAN

Burnout pada tenaga kesehatan, khususnya dokter dan perawat, merupakan persoalan yang memiliki implikasi luas terhadap kesejahteraan tenaga kerja, kualitas pelayanan, dan keselamatan pasien. Kondisi ini umumnya ditandai oleh kelelahan emosional, munculnya sikap sinis atau depersonalisasi, serta menurunnya persepsi terhadap pencapaian profesional. Pengukuran kondisi tersebut dapat dilakukan menggunakan instrumen yang telah terstandar, salah satunya *Maslach Burnout Inventory* (MBI). Tingginya kejadian *burnout* di lingkungan rumah sakit menunjukkan bahwa persoalan ini tidak dapat dipandang hanya sebagai permasalahan individu, tetapi perlu ditangani melalui strategi pencegahan dan intervensi yang lebih sistematis. Beban kerja klinis yang tinggi serta kondisi kerja yang penuh tekanan, termasuk pada periode krisis kesehatan, semakin memperkuat kebutuhan tersebut (Tawfik et al. 2024)(Van Zyl-Cillie et al. 2024) (Wu et al. 2024)(Mohr et al. 2025).

Sejumlah penelitian mengindikasikan bahwa karakteristik pekerjaan memiliki hubungan erat dengan munculnya *burnout* pada tenaga kesehatan. Beban kerja (*workload*) yang tinggi, penerapan sistem kerja *shift*, serta kewajiban administratif menjadi beberapa aspek yang perlu mendapatkan perhatian. Salah satu sumber beban administratif adalah penggunaan *Electronic Health Record* (EHR), yang pada kondisi tertentu dapat menambah tuntutan dokumentasi bagi tenaga kesehatan(Dyrbye et al. 2024)(Gardner et al. 2021)). Tingginya jumlah pasien, durasi kerja yang panjang, frekuensi *shift* yang tinggi, serta kebutuhan menyelesaikan dokumentasi digital dapat meningkatkan tekanan kerja dan kelelahan emosional. Akumulasi kondisi tersebut pada akhirnya dapat memengaruhi kepuasan kerja dan meningkatkan kemungkinan terjadinya *burnout* (West, Dyrbye, and Shanafelt 2022). Dengan demikian, indikator beban kerja dan karakteristik interaksi tenaga kesehatan dengan sistem informasi rumah sakit menjadi aspek yang relevan untuk dimasukkan ke dalam pengembangan model prediksi risiko *burnout*(West, Dyrbye, and Shanafelt 2022). Hasil penelitian sebelumnya menunjukkan bahwa karakteristik beban kerja klinis serta pola

penggunaan sistem informasi rumah sakit memiliki peran penting dalam mengidentifikasi faktor-faktor yang berkaitan dengan risiko *burnout*. Oleh karena itu, kedua aspek tersebut relevan untuk digunakan sebagai variabel dalam pengembangan model prediksi berbasis data(Shanafelt et al. 2023).

Perkembangan teknologi kecerdasan buatan membuka peluang untuk mengembangkan pendekatan prediktif yang memanfaatkan rekam jejak aktivitas kerja tenaga kesehatan. Melalui penerapan *machine learning* dan *deep learning*, berbagai indikator dapat dianalisis secara terpadu, antara lain aktivitas penggunaan *Electronic Health Record* (EHR), durasi kerja, jumlah pasien yang ditangani, waktu pelaksanaan tindakan klinis, serta karakteristik demografis dan pekerjaan. (Fang et al. 2022) (Liu et al. 2025). Penelitian terdahulu memperlihatkan adanya potensi penggunaan *machine learning* (ML) dan *deep learning* dalam mengidentifikasi risiko *burnout* maupun indikator yang berkaitan dengannya melalui pemanfaatan data aktivitas klinis dan administrasi. Namun, kemampuan prediksi yang dihasilkan belum sepenuhnya konsisten antaralgoritma, sementara aspek metodologis seperti kemampuan generalisasi model dan potensi bias pada data masih menjadi tantangan dalam penerapannya. (Kannampallil et al. 2020) (Tawfik et al. 2024). Hasil penelitian terdahulu memberikan dasar untuk mengembangkan model prediktif yang lebih menyeluruh dengan memanfaatkan berbagai indikator beban kerja yang tersedia dalam sistem informasi rumah sakit. Integrasi informasi tersebut dapat mendukung proses identifikasi risiko *burnout* secara lebih dini dan berbasis data. (Van Zyl-Cillie et al. 2024).

Meskipun memiliki potensi yang besar, pengembangan model prediksi *burnout* berbasis kecerdasan buatan masih menghadapi beberapa tantangan. Permasalahan tersebut mencakup perbedaan dalam konsep dan instrumen pengukuran *burnout*, terbatasnya ketersediaan data dari lingkungan eksternal untuk menguji validitas model, serta kemungkinan munculnya bias algoritmik yang dapat memengaruhi ketepatan dan aspek keadilan hasil prediksi.

(Rajkomar et al. 2023). Di samping itu, penggunaan sumber data yang terbatas masih menjadi karakteristik dalam banyak penelitian sebelumnya. Kondisi tersebut menyebabkan pemanfaatan informasi secara terpadu, seperti *log* aktivitas *Electronic Health Record* (EHR), pola jadwal *shift*, dan hasil survei psikologis, belum dilakukan secara optimal. Padahal, penggabungan berbagai jenis data tersebut berpotensi memberikan informasi yang lebih lengkap sehingga dapat mendukung peningkatan kinerja sekaligus interpretabilitas model prediksi *burnout*. (Ghassemi, Oakden-Rayner, and Beam 2021).

Aspek etika, privasi, serta keamanan data tenaga kesehatan perlu menjadi perhatian dalam pemanfaatan data untuk pengembangan model prediktif. Hal ini terutama penting ketika data administratif dan pola perilaku kerja dikumpulkan serta dianalisis dalam rentang waktu yang panjang (*longitudinal*). (Sharma, Davies, and Ainsworth 2021). Agar dapat digunakan dalam lingkungan operasional rumah sakit, model prediksi *burnout* perlu dikembangkan dengan mempertimbangkan aspek transparansi, pengujian pada data eksternal, dan prinsip *fairness*. Selain itu, penerapannya harus didukung oleh tata kelola data yang memadai serta proses evaluasi yang mencakup analisis statistik, pengembangan fitur berdasarkan data sistem informasi rumah sakit, dan pengujian pada kondisi lapangan (WHO 2025).

Pemanfaatan model kecerdasan buatan sebagai bagian dari *dashboard* manajemen Sumber Daya Manusia (SDM) dapat memberikan dukungan bagi rumah sakit dalam mengenali tenaga kesehatan yang memiliki tingkat risiko *burnout* lebih tinggi. Informasi tersebut dapat digunakan sebagai dasar untuk merancang tindakan pencegahan yang lebih sesuai, antara lain melalui penyesuaian distribusi beban kerja, pengelolaan jadwal *shift*, dan pemberian dukungan psikososial kepada staf yang membutuhkan (Bates et al. 2021) (Canfell et al. 2024).

Dengan tersedianya informasi prediktif, manajemen rumah sakit dapat melakukan perencanaan dan pengambilan keputusan secara lebih proaktif berdasarkan pola yang ditemukan dari data operasional.

Pendekatan tersebut juga berpotensi mendukung peningkatan retensi tenaga kesehatan, kepuasan

kerja, dan kualitas pelayanan klinis karena intervensi dapat diarahkan pada faktor pekerjaan yang berkaitan dengan risiko *burnout* (Bates et al. 2021). Dari perspektif keselamatan pasien, pemanfaatan analitik prediktif dalam sistem informasi rumah sakit dapat membantu mengidentifikasi kondisi kerja yang berpotensi meningkatkan kelelahan staf dan menjadi pertimbangan dalam optimalisasi pengelolaan sumber daya manusia (Topol 2019). Dengan demikian, penelitian ini diharapkan tidak hanya memberikan kontribusi pada pengembangan kajian *machine learning* untuk prediksi *burnout*, tetapi juga menawarkan manfaat praktis bagi pengelolaan tenaga kesehatan yang berkelanjutan serta peningkatan mutu pelayanan rumah sakit (Wosny, Strasser, and Hastings 2023).

KAJIAN LITERATUR

Konsep *Burnout* pada Tenaga Kesehatan

Burnout pada tenaga kesehatan dapat dipahami sebagai respons terhadap tekanan kerja yang berlangsung secara terus-menerus dan ditunjukkan melalui kelelahan emosional, munculnya sikap sinis atau depersonalisasi terhadap pasien, serta menurunnya perasaan terhadap pencapaian profesional (Dyrbye et al. 2024). Kondisi ini relatif sering ditemukan pada dokter dan perawat karena kelompok tersebut menghadapi tuntutan pelayanan klinis yang tinggi, kewajiban administratif, keterbatasan waktu, serta tanggung jawab besar dalam menjaga keselamatan pasien (West, Dyrbye, and Shanafelt 2022). Dampak *burnout* tidak terbatas pada aspek psikologis dan kondisi fisik tenaga kesehatan, tetapi juga dapat berpengaruh terhadap mutu pelayanan, meningkatkan kemungkinan terjadinya kesalahan medis, serta mendorong *turnover* dan keinginan untuk meninggalkan profesi (Shanafelt et al. 2023). Dengan demikian, *burnout* perlu dilihat sebagai persoalan yang berkaitan dengan sistem organisasi dan kondisi lingkungan kerja rumah sakit, bukan hanya sebagai persoalan personal tenaga kesehatan (Khatatbeh et al. 2022).

Teori Beban Kerja (*Workload Theory*)

Workload theory memandang beban kerja sebagai keseluruhan tuntutan fisik, mental, dan waktu yang harus dikelola seseorang dalam menjalankan pekerjaannya. Ketika tuntutan

tersebut melampaui kemampuan individu untuk beradaptasi, kondisi tersebut dapat memicu stres dan kelelahan kerja. Pada lingkungan pelayanan kesehatan, beban kerja tenaga klinis tidak hanya berkaitan dengan jumlah pasien, tetapi juga mencakup tingkat kompleksitas kasus, lama waktu bekerja, intensitas *shift*, serta pekerjaan administratif, termasuk kegiatan dokumentasi melalui sistem informasi. Beban kerja yang tinggi dan berlangsung secara berkelanjutan dapat memperbesar kelelahan emosional serta menurunkan kepuasan kerja. Kondisi tersebut pada akhirnya menjadi salah satu faktor yang berperan dalam peningkatan risiko *burnout* pada tenaga kesehatan (West, Dyrbye, and Shanafelt 2022).

Sistem Informasi Rumah Sakit dan *Electronic Health Record* (EHR)

Sistem Informasi Rumah Sakit (SIRS) berfungsi sebagai platform terintegrasi untuk mengelola berbagai informasi yang berkaitan dengan aktivitas klinis, administrasi, dan manajemen rumah sakit guna menunjang penyelenggaraan pelayanan serta proses pengambilan keputusan. Salah satu bagian penting dalam sistem tersebut adalah *Electronic Health Record* (EHR), yang memungkinkan pencatatan aktivitas pelayanan pasien dilakukan secara digital. Pemanfaatan EHR dapat mendukung ketersediaan dan kesinambungan dokumentasi klinis, tetapi pada sisi lain juga dapat menambah tuntutan administratif dan beban kognitif tenaga kesehatan. Penggunaan sistem yang tidak disertai pengelolaan alur kerja yang tepat berpotensi menyebabkan fragmentasi pekerjaan, meningkatkan tekanan kerja, dan pada akhirnya berkontribusi terhadap munculnya stres serta *burnout* pada tenaga kesehatan. (Gardner et al. 2021).

Kecerdasan Buatan (*Artificial Intelligence*)

Kecerdasan buatan (*Artificial Intelligence/AI*) merupakan bidang ilmu komputer yang berfokus pada pengembangan sistem yang mampu meniru kemampuan kognitif manusia, seperti belajar dari data, mengenali pola, dan mengambil keputusan secara otomatis (Raharja et al. 2024). Dalam sektor kesehatan, AI dimanfaatkan untuk analitik prediktif, pengambilan keputusan klinis, serta optimasi manajemen sumber daya, termasuk

pengelolaan tenaga kesehatan. Penerapan AI memungkinkan pemrosesan data berskala besar dari sistem informasi rumah sakit untuk menghasilkan wawasan yang mendukung pengambilan keputusan berbasis bukti, sekaligus meningkatkan efisiensi operasional dan kualitas layanan kesehatan (Topol 2019).

Machine Learning* dan *Deep Learning

Kecerdasan buatan (*Artificial Intelligence/AI*) merupakan teknologi yang dikembangkan untuk memungkinkan komputer melakukan berbagai fungsi yang umumnya memerlukan kemampuan kognitif manusia, termasuk mempelajari informasi, mengenali pola, dan menghasilkan keputusan berdasarkan data (Putra et al. 2025). Pemanfaatan AI dalam bidang kesehatan telah berkembang pada berbagai kebutuhan, seperti analisis prediktif, dukungan terhadap pengambilan keputusan klinis, serta pengelolaan sumber daya kesehatan. Dalam konteks manajemen rumah sakit, teknologi ini memungkinkan pengolahan data dalam jumlah besar yang berasal dari sistem informasi rumah sakit untuk menemukan pola dan informasi yang dapat digunakan sebagai dasar pengambilan keputusan berbasis bukti. Penerapan tersebut juga berpotensi meningkatkan efisiensi proses operasional sekaligus mendukung peningkatan mutu pelayanan kesehatan. (Lou et al., 2022).

METODE PENELITIAN

Desain dan Pendekatan Penelitian

Penelitian ini menerapkan pendekatan kuantitatif analitik dengan rancangan prediktif berbasis data untuk membangun serta menguji model kecerdasan buatan (*machine learning*) dalam mengidentifikasi risiko *burnout* pada staf klinis. Data yang digunakan merepresentasikan karakteristik pekerjaan dan beban kerja tenaga kesehatan, meliputi jumlah pasien yang dilayani, durasi kerja, pola *shift*, serta aktivitas pada *Electronic Health Record* (EHR). Seluruh variabel tersebut digunakan sebagai masukan dalam proses pemodelan untuk memperoleh pola yang berkaitan dengan tingkat *burnout* yang telah diukur menggunakan instrumen terstandar. Selanjutnya, data dianalisis secara sistematis melalui proses pelatihan model *machine learning* guna menghasilkan prediksi risiko *burnout*. Hasil pemodelan diharapkan dapat memberikan

informasi prediktif yang akurat dan dapat digunakan sebagai salah satu dasar bagi manajemen rumah sakit dalam melakukan deteksi dini serta merancang langkah pencegahan *burnout* pada staf klinis.

Subjek Penelitian

Penelitian ini melibatkan 120 staf klinis rumah sakit yang terdiri atas dokter dan perawat yang secara langsung menjalankan pelayanan kepada pasien. Pemilihan kelompok tersebut didasarkan pada tingginya intensitas interaksi dengan pasien serta besarnya tuntutan pekerjaan klinis dan administratif yang dihadapi dalam aktivitas sehari-hari. Para responden juga merupakan pengguna sistem informasi rumah sakit dan *Electronic Health Record* (EHR), sehingga berbagai aktivitas terkait pekerjaan dan beban kerja dapat direkam secara sistematis. Informasi tersebut selanjutnya dimanfaatkan sebagai sumber data dalam membangun model prediksi risiko *burnout*.

Sumber dan Jenis Data

Data penelitian berasal dari dua sumber utama, yaitu data primer dan data sekunder. Data sekunder diperoleh dari sistem informasi rumah sakit, terutama rekaman aktivitas *Electronic Health Record* (EHR), yang meliputi frekuensi penggunaan sistem, durasi aktivitas, jumlah pasien yang ditangani, waktu kerja, serta karakteristik jadwal *shift*. Sementara itu, data primer berupa tingkat *burnout* diperoleh dari pengukuran langsung terhadap staf klinis menggunakan instrumen yang telah terstandar dan tervalidasi. Penggabungan kedua sumber data tersebut memungkinkan karakteristik pekerjaan dan beban kerja dianalisis bersama dengan kondisi *burnout* yang dialami oleh responden.

Teknik Pengumpulan Data

Pengumpulan data sekunder dilakukan melalui ekstraksi informasi dari sistem informasi rumah sakit dengan fokus pada aktivitas EHR dan indikator beban kerja staf klinis. Proses ekstraksi dilaksanakan secara terstruktur untuk menjaga kelengkapan, konsistensi, dan keamanan data yang digunakan dalam penelitian. Adapun data primer diperoleh melalui pengisian kuesioner

oleh responden dengan menggunakan instrumen pengukuran *burnout* yang telah tervalidasi. Data hasil pengukuran tersebut digunakan sebagai variabel keluaran (*target variable*) dalam proses pengembangan model prediksi.

Model AI yang Digunakan

Penelitian ini menggunakan pendekatan *supervised machine learning* untuk melakukan klasifikasi terhadap tingkat risiko *burnout* staf klinis. Pendekatan tersebut dipilih karena kategori keluaran telah ditentukan berdasarkan hasil pengukuran tingkat *burnout* menggunakan instrumen terstandar. Tiga algoritma digunakan dalam proses pemodelan, yaitu *Logistic Regression*, *Random Forest*, dan *Gradient Boosting*. *Logistic Regression* digunakan sebagai model pembanding karena memiliki tingkat interpretabilitas yang relatif baik, sedangkan *Random Forest* dan *Gradient Boosting* dipilih karena mampu memodelkan hubungan nonlinier serta interaksi antarvariabel. Perbandingan ketiga algoritma dilakukan untuk menentukan model yang memberikan kinerja prediksi paling optimal.

Teknik Analisis dan Evaluasi Model

Tahapan analisis dimulai dengan *data preprocessing*, yang mencakup pemeriksaan dan pembersihan data, penanganan nilai yang hilang, serta penyesuaian format data sebelum digunakan dalam proses pemodelan. Selanjutnya dilakukan *feature engineering* untuk menghasilkan atau menentukan variabel yang paling relevan dalam merepresentasikan pola kerja dan beban kerja staf klinis. Data yang telah dipersiapkan kemudian digunakan dalam proses pelatihan (*model training*) menggunakan ketiga algoritma yang telah ditetapkan. Kinerja masing-masing model dibandingkan berdasarkan nilai akurasi, *precision*, *recall*, dan *Area Under the Curve* (AUC). Evaluasi tersebut digunakan untuk mengetahui kemampuan model dalam membedakan dan mengklasifikasikan tingkat risiko *burnout* secara konsisten serta menentukan algoritma dengan performa terbaik.

PEMBAHASAN

Gambaran Umum Risiko *Burnout* Staf Klinis

Hasil pengukuran menunjukkan bahwa staf klinis dalam penelitian ini memiliki tingkat risiko *burnout* yang beragam, mulai dari kategori rendah hingga tinggi. Kondisi tersebut memperlihatkan bahwa *burnout* merupakan persoalan yang perlu diperhatikan dalam lingkungan kerja rumah sakit, terutama pada tenaga kesehatan yang menghadapi tuntutan pekerjaan yang besar. Intensitas pelayanan, keterbatasan waktu dalam menyelesaikan tugas, serta tanggung jawab terhadap keselamatan pasien menjadi karakteristik pekerjaan yang dapat meningkatkan tekanan psikologis dan berkontribusi terhadap kelelahan emosional staf klinis.

Perbedaan risiko juga terlihat berdasarkan profesi dan pola kerja. Kelompok perawat memiliki proporsi risiko *burnout* sedang hingga tinggi yang lebih besar dibandingkan kelompok dokter. Kondisi ini dapat berkaitan dengan tingginya

frekuensi interaksi langsung dengan pasien, tuntutan pekerjaan yang berlangsung secara berkelanjutan, serta penerapan sistem *shift*. Hal serupa terlihat pada staf yang bekerja dengan sistem *shift*, yang menunjukkan proporsi risiko *burnout* sedang hingga tinggi lebih besar dibandingkan staf dengan pola kerja *non-shift*. Pola kerja tersebut dapat memengaruhi waktu istirahat dan keseimbangan kehidupan kerja. Selain karakteristik jadwal, tingginya jumlah pasien dan panjangnya waktu kerja juga menunjukkan kecenderungan hubungan dengan peningkatan risiko *burnout*. Temuan ini menunjukkan bahwa kondisi organisasi dan karakteristik pekerjaan perlu menjadi bagian penting dalam strategi pengelolaan risiko *burnout*. Oleh karena itu, penggunaan model AI sebagai alat bantu deteksi dini dapat dipertimbangkan untuk membantu manajemen rumah sakit mengidentifikasi kelompok yang memerlukan perhatian dan menentukan intervensi secara lebih terarah.

Tabel 1. Distribusi Risiko Burnout Berdasarkan Karakteristik Responden (n = 120)

Karakteristik	Kategori	Risiko Rendah n (%)	Risiko Sedang n (%)	Risiko Tinggi n (%)	Total
Profesi	Dokter	22 (48,9)	15 (33,3)	8 (17,8)	45
	Perawat	25 (33,3)	32 (42,7)	18 (24,0)	75
Pola Kerja	Shift	22 (26,8)	36 (43,9)	24 (29,3)	82
	Non-shift	25 (65,8)	11 (28,9)	2 (5,3)	38
Beban Kerja	Tinggi	12 (21,8)	26 (47,3)	17 (30,9)	55
	Sedang–Rendah	35 (53,8)	21 (32,3)	9 (13,9)	65

Sumber: Data primer yang diolah peneliti (2026).

Hubungan Pola Kerja dan Beban Kerja dengan Risiko Burnout

Karakteristik beban kerja menjadi salah satu aspek yang perlu diperhatikan dalam memahami variasi risiko *burnout* pada staf klinis. Dalam penelitian ini, indikator yang digunakan mencakup jumlah pasien, durasi kerja, dan pola *shift*. Staf yang menghadapi volume pelayanan lebih besar serta waktu kerja yang lebih panjang cenderung memiliki risiko *burnout* pada kategori sedang hingga tinggi. Kondisi tersebut dapat dijelaskan melalui perspektif *job demands-resources*, yaitu ketika tuntutan pekerjaan meningkat sementara sumber daya yang tersedia tidak memadai, individu dapat mengalami kelelahan emosional dan kesulitan mempertahankan kinerja serta kesejahteraan psikologis.

Risiko *burnout* juga berkaitan dengan tuntutan administratif yang muncul melalui penggunaan *Electronic Health Record* (EHR). Intensitas penggunaan sistem, baik dari sisi frekuensi maupun durasi, menjadi indikator penting dalam menggambarkan beban dokumentasi digital yang harus diselesaikan oleh tenaga kesehatan. Beban tersebut menjadi semakin relevan ketika proses dokumentasi harus dilakukan dalam waktu terbatas atau setelah pelayanan langsung kepada pasien selesai. Kondisi ini dapat menambah tuntutan kognitif dan tekanan kerja yang dirasakan staf klinis.


Dengan mempertimbangkan kedua aspek tersebut, beban kerja klinis dan aktivitas EHR dapat dipandang sebagai sumber informasi yang relevan dalam pemodelan risiko *burnout*. Penggabungan indikator jumlah pasien, waktu kerja, pola *shift*, serta aktivitas EHR memberikan representasi yang lebih menyeluruh mengenai karakteristik pekerjaan staf klinis. Oleh karena itu, variabel-variabel tersebut digunakan sebagai bagian penting dalam pengembangan model AI untuk mendukung identifikasi risiko *burnout* secara berbasis data.

Tabel 2. Distribusi Risiko Burnout Berdasarkan Beban Kerja dan Aktivitas EHR (n = 120)

Variabel	Kategori	Risiko Rendah n (%)	Risiko Sedang n (%)	Risiko Tinggi n (%)	Total
Jumlah Pasien	Tinggi	10 (20,0)	22 (44,0)	18 (36,0)	50
Profesi	Dokter	22 (48,9)	15 (33,3)	8 (17,8)	45
	Perawat	25 (33,3)	32 (42,7)	18 (24,0)	75
Pola Kerja	Shift	22 (26,8)	36 (43,9)	24 (29,3)	82
	Non-shift	25 (65,8)	11 (28,9)	2 (5,3)	38
Beban Kerja	Tinggi	12 (21,8)	26 (47,3)	17 (30,9)	55
	Sedang-Rendah	35 (53,8)	21 (32,3)	9 (13,9)	65

Sumber: Data primer dan data Sistem Informasi Rumah Sakit (SIRS)/*Electronic Health Record* (EHR) yang diolah peneliti (2026).

Kinerja Model AI dalam Memprediksi Risiko Burnout




Gambar 4.1. Proporsi Kontribusi Akurasi
Sumber: Data penelitian yang diolah peneliti (2026).

Gambar 4.1 memperlihatkan perbandingan kinerja tiga algoritma *machine learning* yang digunakan untuk memprediksi risiko

burnout, yaitu *Logistic Regression*, *Random Forest*, dan *Gradient Boosting*. Berdasarkan nilai akurasi aktual, *Gradient Boosting* memperoleh hasil tertinggi sebesar 0,87. Selanjutnya, *Random Forest* menghasilkan akurasi sebesar 0,84, sedangkan *Logistic Regression* memperoleh nilai sebesar 0,78. Jika nilai tersebut disajikan dalam bentuk proporsi relatif terhadap keseluruhan akurasi ketiga model, masing-masing model memiliki kontribusi sebesar 34,9%, 33,7%, dan 31,3%.

Perbedaan tersebut menunjukkan bahwa *Gradient Boosting* memberikan performa klasifikasi yang paling baik dibandingkan dua algoritma lainnya. Kemampuan model ini dalam menangkap pola yang lebih kompleks pada data memungkinkan proses identifikasi risiko *burnout* dilakukan dengan tingkat akurasi yang lebih tinggi. Meskipun demikian, ketiga algoritma tetap memberikan hasil prediksi yang dapat digunakan dalam analisis, sebagaimana terlihat dari rentang proporsi relatif yang tidak terlalu jauh, yaitu sekitar 31% hingga 35%.

Dengan demikian, berdasarkan metrik akurasi, *Gradient Boosting* dipilih sebagai model dengan kinerja terbaik dalam penelitian ini. Nilai akurasi aktual sebesar 0,87 menjadi dasar utama dalam menentukan keunggulan model tersebut, sementara nilai proporsi relatif pada Gambar 4.1 digunakan untuk memberikan gambaran visual mengenai perbandingan kinerja ketiga algoritma.



Gambar 4.2. Perbandingan Kinerja Tiga Model *Machine Learning*

Sumber: Data penelitian yang diolah peneliti (2026).

Gambar 4.2 menyajikan perbandingan kemampuan klasifikasi *Logistic Regression*, *Random Forest*, dan *Gradient Boosting* berdasarkan nilai *Area Under the Curve* (AUC). Metrik AUC digunakan untuk menggambarkan kemampuan model dalam membedakan staf dengan risiko *burnout* dari staf dengan risiko yang lebih rendah. Hasil pengujian menunjukkan bahwa *Gradient Boosting* memperoleh nilai AUC tertinggi, yaitu 0,91, kemudian diikuti oleh *Random Forest* sebesar 0,88 dan *Logistic Regression* sebesar 0,80. Dalam visualisasi proporsi relatif, ketiga model masing-masing memiliki nilai 35,1%, 34,0%, dan 30,9%.

Nilai AUC tersebut menunjukkan adanya perbedaan kemampuan diskriminasi antaralgoritma. *Logistic Regression* tetap mampu memberikan hasil klasifikasi yang baik dengan AUC 0,80, sedangkan peningkatan nilai AUC pada *Random Forest* dan *Gradient Boosting* menunjukkan kemampuan yang lebih tinggi dalam mengenali pola risiko *burnout*. Hasil ini memperkuat temuan pada metrik akurasi bahwa *Gradient Boosting* merupakan algoritma dengan kinerja paling optimal dalam penelitian ini. Kemampuannya dalam memodelkan hubungan nonlinier dan interaksi antarvariabel menjadi salah satu alasan model tersebut menghasilkan nilai AUC tertinggi.

Kontribusi Variabel terhadap Prediksi *Burnout*

Prediksi risiko *burnout* pada staf klinis berkaitan dengan sejumlah karakteristik pekerjaan, terutama pola kerja, beban pelayanan, dan aktivitas penggunaan EHR. Pola *shift*, termasuk jadwal kerja malam dan ketidakteraturan waktu kerja, dapat memengaruhi waktu istirahat serta keseimbangan aktivitas kerja. Sementara itu, jumlah pasien yang harus ditangani dan tuntutan administratif menggambarkan besarnya beban pekerjaan yang harus diselesaikan oleh tenaga kesehatan.

Aktivitas EHR juga menjadi salah satu aspek yang perlu diperhatikan karena proses pencatatan dan peninjauan rekam medis dapat menambah tuntutan administratif. Indikator seperti frekuensi *chart review* dan durasi penggunaan sistem dapat memberikan gambaran mengenai intensitas aktivitas digital staf klinis. Kombinasi antara beban pelayanan, pola *shift*, dan aktivitas EHR dapat membentuk kondisi kerja dengan tingkat tuntutan yang berbeda pada setiap staf.

Penggunaan *Gradient Boosting* memberikan keuntungan dalam menganalisis hubungan yang tidak bersifat linier antarvariabel. Model dapat mempertimbangkan keterkaitan beberapa karakteristik pekerjaan secara bersamaan dalam menghasilkan prediksi risiko *burnout*. Namun, penentuan variabel yang paling dominan sebaiknya didasarkan pada hasil analisis kontribusi fitur yang terukur, seperti *feature importance* atau metode interpretabilitas model, bukan hanya berdasarkan asumsi teoritis. Dengan demikian, interpretasi mengenai faktor yang paling berpengaruh terhadap prediksi dapat disampaikan secara objektif sesuai dengan hasil model.

Implikasi Manajerial bagi Rumah Sakit

Hasil penelitian menunjukkan bahwa model *Gradient Boosting* dapat dipertimbangkan sebagai salah satu alat pendukung bagi manajemen rumah sakit dalam melakukan identifikasi awal terhadap risiko *burnout* pada staf klinis. Pemanfaatan model memungkinkan informasi mengenai pola kerja, beban pelayanan, dan aktivitas EHR dianalisis secara bersamaan untuk menghasilkan gambaran tingkat risiko pada kelompok staf. Pendekatan ini dapat melengkapi metode evaluasi konvensional yang dilakukan secara berkala sehingga manajemen memiliki informasi berbasis data dalam menentukan kelompok yang memerlukan perhatian lebih lanjut. Dengan tersedianya informasi tersebut, tindakan pencegahan dapat diarahkan pada faktor pekerjaan yang berkaitan dengan peningkatan risiko *burnout*.

Dari perspektif pengelolaan SDM, hasil prediksi dapat menjadi salah satu bahan pertimbangan dalam melakukan penyesuaian distribusi beban kerja. Informasi mengenai risiko juga dapat digunakan untuk mengevaluasi pola penjadwalan *shift* dan mengidentifikasi kondisi kerja yang berpotensi menimbulkan beban berlebih. Dengan demikian, pengaturan jadwal dan pembagian tugas dapat dilakukan dengan mempertimbangkan karakteristik beban kerja masing-masing kelompok staf. Pendekatan tersebut dapat membantu menciptakan distribusi pekerjaan yang lebih proporsional tanpa menjadikan hasil prediksi sebagai satu-satunya dasar dalam pengambilan keputusan.

Model prediktif juga dapat mendukung perencanaan intervensi preventif secara lebih terarah. Staf atau kelompok yang teridentifikasi memiliki risiko lebih tinggi dapat menjadi sasaran evaluasi lanjutan, pemberian dukungan psikososial, atau program pendampingan yang sesuai. Dalam penerapannya, hasil prediksi perlu diposisikan sebagai informasi pendukung dan tetap dikombinasikan dengan evaluasi profesional serta pertimbangan kondisi individual staf. Dengan pendekatan tersebut, pemanfaatan AI tidak hanya diarahkan pada peningkatan kemampuan prediksi, tetapi juga pada penguatan pengambilan keputusan berbasis data untuk mendukung kesejahteraan tenaga kesehatan dan keberlanjutan pengelolaan SDM rumah sakit.

PENUTUP

Penelitian ini mengembangkan dan mengevaluasi pendekatan *machine learning* untuk mengidentifikasi risiko *burnout* pada staf klinis dengan memanfaatkan informasi mengenai pola kerja dan beban kerja yang berasal dari Sistem Informasi Rumah Sakit (SIRS) dan *Electronic Health Record* (EHR). Hasil analisis memperlihatkan bahwa karakteristik pekerjaan, seperti jumlah pasien, durasi kerja, pola *shift*, serta intensitas aktivitas EHR, berkaitan dengan variasi tingkat risiko *burnout*. Kelompok

perawat dan staf dengan pola kerja *shift* menunjukkan proporsi risiko sedang hingga tinggi yang lebih besar. Temuan tersebut menunjukkan pentingnya mempertimbangkan faktor organisasi dan karakteristik pekerjaan dalam pengelolaan risiko *burnout* tenaga kesehatan. Hasil perbandingan tiga algoritma menunjukkan bahwa *Gradient Boosting* memberikan kinerja prediksi terbaik dengan akurasi aktual sebesar **0,87** dan AUC sebesar **0,91**. Hasil tersebut menunjukkan bahwa algoritma *Gradient Boosting* memiliki kemampuan klasifikasi yang lebih baik dibandingkan *Logistic Regression* dan *Random Forest* dalam penelitian ini, khususnya dalam mengenali pola hubungan yang kompleks pada data risiko *burnout*. Secara praktis, model yang dikembangkan berpotensi menjadi alat bantu bagi manajemen rumah sakit dalam melakukan identifikasi awal terhadap staf atau kelompok kerja yang memiliki risiko *burnout* lebih tinggi. Informasi prediktif tersebut dapat digunakan sebagai bahan pertimbangan dalam evaluasi distribusi beban kerja, pengelolaan jadwal *shift*, serta perencanaan intervensi preventif dan dukungan psikososial. Dengan demikian, pemanfaatan analitik prediktif dapat mendukung pengambilan keputusan SDM yang lebih berbasis data dan menjadi salah satu pendekatan untuk memperkuat pengelolaan tenaga kesehatan secara berkelanjutan.

REFERENSI

- Bates, David W, David Levine, Ania Syrowatka, Masha Kuznetsova, Kelly Jean Thomas Craig, Angela Rui, Gretchen Purcell Jackson, and Kyu Rhee. 2021. "The Potential of Artificial Intelligence to Improve Patient Safety: A Scoping Review." *NPJ digital medicine* 4(1): 54. doi:10.1038/s41746-021-00423-6.
- Canfell, Oliver J, Leanna Woods, Yasaman Meshkat, and Jenna Krivit. 2024. "The Impact of Digital Hospitals on Patient and Clinician Experience : Systematic Review and Qualitative Evidence Synthesis Corresponding Author :” 26: 1–24. doi:10.2196/47715.
- Dyrbye, Lotte, Tait Shanafelt, Christine Sinsky, Pamela Cipriano, Jay Bhatt, Alexander Ommaya, Colin West, and David Meyers. 2024. "Burnout Among Health Care Professionals: A Call to Explore and Address This Underrecognized Threat to Safe, High-Quality Care.” *NAM Perspectives* 7. doi:10.31478/201707b.
- Fang, Yilu, Betina Idnay, Yingcheng Sun, Hao Liu, Zhehuan Chen, Karen Marder, Hua Xu, Rebecca Schnall, and Chunhua Weng. 2022. "Combining Human and Machine Intelligence for Clinical Trial Eligibility Querying.” *Journal of the American Medical Informatics Association* 29(7): 1161–71. doi:10.1093/jamia/ocac051.
- Gardner, Rebekah L, Emily Cooper, Jacqueline Haskell, Daniel A Harris, Sara Poplau, Philip J Kroth, and Mark Linzer. 2021. "Physician Stress and Burnout: The Impact of Health Information Technology.” *Journal of the American Medical Informatics Association : JAMIA* 26(2): 106–14. doi:10.1093/jamia/ocy145.
- Ghassemi, Marzyeh, Luke Oakden-Rayner, and Andrew L Beam. 2021. "The False Hope of Current Approaches to Explainable Artificial Intelligence in Health Care.” *The Lancet Digital Health* 3(11): e745–50. doi:10.1016/S2589-7500(21)00208-9.
- Kannampallil, Thomas, Joanna Abraham, Sunny Lou, and Philip Payne. 2020. "Conceptual Considerations for Using EHR-Based Activity Logs to Measure Clinician Burnout and Its Effects.” *Journal of the American Medical Informatics Association* 28. doi:10.1093/jamia/ocaa305.
- Khatatbeh, Haitham, Annamária Pakai, Tariq Al-Dwaikat, David Onchonga, Faten Amer, Viktória Prémusz, and András Oláh. 2022. "Nurses' Burnout and Quality of Life: A Systematic

- Review and Critical Analysis of Measures Used.” *Nursing open* 9(3): 1564–74. doi:10.1002/nop2.936.
- Liu, Chao, Yen-Ching Chuang, Lifan Qin, Lijie Ren, Ching-Wen Chien, and Tao-Hsin Tung. 2025. “Machine-Learning-Based Model for Analysing and Accurately Predicting Factors Related to Burnout in Healthcare Workers.” *BMJ public health* 3(2): e000777. doi:10.1136/bmjph-2023-000777.
- Mohr, David C, Shereef Elnahal, Maureen L Marks, Ryan Derickson, and Katherine Osatuke. 2025. “Burnout Trends Among US Health Care Workers.” *JAMA network open* 8(4): e255954. doi:10.1001/jamanetworkopen.2025.5954.
- Putra, V H Cahaya, A Rachmat Raharja, G Kanugrahan, C Tho, and M Al-Husaini. 2025. “Advanced Machine Learning Models for Predicting Irrigation Water Quality: A Comparative Study of LSTM, SVM, and XGBoost Algorithms in Rice Cultivation.” In *2025 International Conference on Information Management and Technology (ICIMTech)*, , 234–39. doi:10.1109/ICIMTech67074.2025.11265474.
- Raharja, A R, V H C Putra, G Kanugrahan, and C Tho. 2024. “Indonesian Sign Language (SIBI) Detection: A Landmark-Based Approach with Scikit-Learn Utilizing Random Forest Classifier.” In *2024 Ninth International Conference on Informatics and Computing (ICIC)*, , 1–8. doi:10.1109/ICIC64337.2024.10956917.
- Rajkomar, Alvin, Michaela Hardt, Michael D Howell, Greg Corrado, and Marshall H Chin. 2023. “Ensuring Fairness in Machine Learning to Advance Health Equity.” *Annals of internal medicine* 169(12): 866–72. doi:10.7326/M18-1990.
- Shanafelt, Tait D, Christine Sinsky, Lotte N Dyrbye, Mickey Trockel, and Colin P West. 2023. “Burnout Among Physicians Compared With Individuals With a Professional or Doctoral Degree in a Field Outside of Medicine.” *Mayo Clinic proceedings* 94(3): 549–51. doi:10.1016/j.mayocp.2018.11.035.
- Sharma, Videha, Angela Davies, and John Ainsworth. 2021. “Clinical Risk Prediction Models: The Canary in the Coalmine for Artificial Intelligence in Healthcare?” *BMJ Health & Care Informatics* 28(1): e100421. doi:10.1136/bmjhci-2021-100421.
- Tawfik, Daniel, Mohsen Bayati, Jessica Liu, Liem Nguyen, Amrita Sinha, Thomas Kannampallil, Tait Shanafelt, and Jochen Profit. 2024. “Predicting Primary Care Physician Burnout From Electronic Health Record Use Measures.” *Mayo Clinic Proceedings* 99(9): 1411–21. doi:10.1016/j.mayocp.2024.01.005.
- Topol, Eric J. 2019. “High-Performance Medicine: The Convergence of Human and Artificial Intelligence.” *Nature medicine* 25(1): 44–56. doi:10.1038/s41591-018-0300-7.
- West, Colin, Liselotte Dyrbye, and Tait Shanafelt. 2022. “Physician Burnout: Contributors, Consequences, and Solutions.” *Journal of Internal Medicine* 283. doi:10.1111/joim.12752.
- WHO. 2025. *Ethics and Governance of Artificial Intelligence for Health*.
- Wosny, Marie, Livia Maria Strasser, and Janna Hastings. 2023. “Experience of Health Care Professionals Using Digital Tools in the Hospital: Qualitative Systematic Review Corresponding Author :” 10: 1–21. doi:10.2196/50357.
- Wu, Yuxuan, Mingyue Wu, Changyu Wang, Jie Lin, Jialin Liu, and Siru Liu. 2024. “Evaluating the Prevalence of Burnout Among Health Care Professionals Related to Electronic Health Record Use: Systematic Review and Meta-

Analysis.” *JMIR Med Inform* 12: e54811. doi:10.2196/54811.

Van Zyl-Cillie, Maria Magdalena, Jacoba H Bührmann, Alwiena J Blignaut, Derya Demirtas, and Siedine K Coetzee. 2024. “A Machine Learning Model to Predict the Risk Factors Causing Feelings of Burnout and Emotional Exhaustion amongst Nursing Staff in South Africa.” *BMC Health Services Research* 24(1): 1665. doi:10.1186/s12913-024-12184-5.

BIODATA PENULIS

1. Dola Ramanlinda adalah dosen tetap prodi Perekan dan Informasi Kesehatan pada Universitas Bandung.
2. Yudi Darsono adalah dosen tetap prodi Sistem Informasi pada Universitas Bandung.
3. Agung Rachmat Raharja adalah dosen tetap prodi Perekan dan Informasi Kesehatan pada Universitas Bandung.