

ARTIFICIAL INTELLIGENCE SEBAGAI PENINGKATAN PEMANTAUAN PERUBAHAN HEMODINAMIK DI ICU: TINJAUAN SISTEMATIS TERHADAP ALGORITMA PREDIKTIF DAN HASIL KLINIS

Artificial intelligence for Enhancing Hemodynamic Monitoring in the ICU: A Systematic review of Predictive algorithms and Clinical outcomes

Shintia Ekawati¹, Fitri Handayani²

^{1,2} Rumah Sakit Pusat Angkatan Laut dr. Ramelan Surabaya, Indonesia

ABSTRAK

Instabilitas hemodinamik merupakan prediktor utama kegagalan organ dan mortalitas pada pasien ICU. Monitoring konvensional sering gagal mendeteksi perburukan dini, sehingga mendorong pemanfaatan kecerdasan buatan (AI) untuk meningkatkan kemampuan deteksi dan prediksi ketidakstabilan hemodinamik. Systematic review ini mengikuti pedoman PRISMA 2020 dan menganalisis studi yang menggunakan machine learning atau deep learning untuk memprediksi hipotensi, kebutuhan vasopressor, atau instabilitas hemodinamik pada pasien dewasa di ICU. Enam database utama disaring, dan 16 studi memenuhi kriteria inklusi. Karena heterogenitas desain model dan luaran, sintesis dilakukan secara naratif. Studi yang diinklusi mencakup pengembangan model retrospektif, validasi multicenter, evaluasi prospektif, serta dua uji klinis teracak. Model multivariabel seperti HSI menunjukkan performa prediksi yang kuat (AUROC 0,76–0,90). Model dinamis seperti TvHEWS konsisten memberikan prediksi stabil dengan pengurangan false alarms. Prediktor berbasis waveform, termasuk HPI, mampu mengantisipasi hipotensi 5–15 menit sebelum onset, bahkan pada pasien sepsis. Pendekatan personalisasi (DynaCEL, HM-TARGET) menghasilkan target hemodinamik spesifik pasien. Studi prospektif menunjukkan penurunan durasi hipotensi, namun bukti dampak terhadap mortalitas dan kegagalan organ masih terbatas. AI berpotensi meningkatkan ketepatan monitoring hemodinamik dan intervensi dini di ICU, namun diperlukan uji klinis berskala besar untuk memastikan manfaat terhadap luaran klinis yang bermakna.

Kata Kunci: kecerdasan buatan, monitoring

Article info

Received : 20 Desember 2025

Accepted : 22 Mei 2026

Published : 20 Juni 2026

Corresponding author

Shintia Ekawati

Rumah Sakit Pusat Angkatan
Laut dr. Ramelan Surabaya,
Indonesia
Shintiaeka8@gmail.com

Website

<https://jkki.hipercci.com>

E-ISSN : 3047 - 2865

hemodinamik, prediksi hipotensi, ICU, machine learning, model prediktif

ABSTRACT

Hemodynamic instability is a primary predictor of organ failure and mortality in ICU patients. Conventional monitoring often fails to detect early deterioration, driving the adoption of artificial intelligence (AI) to enhance the detection and prediction of hemodynamic instability. This systematic review follows the PRISMA 2020 guidelines and analyzes studies utilizing machine learning or deep learning to predict hypotension, vasopressor requirements, or hemodynamic instability in adult ICU patients. Six major databases were screened, and 16 studies met the inclusion criteria. Due to the heterogeneity of model designs and outcomes, a narrative synthesis was performed. The included studies encompassed retrospective model development, multicenter validation, prospective evaluation, and two randomized clinical trials. Multivariable models such as HSI demonstrated robust predictive performance (AUROC 0.76–0.90). Dynamic models like TvHEWS consistently provided stable predictions with a reduction in false alarms. Waveform-based predictors, including HPI, were able to anticipate hypotension 5–15 minutes before onset, even in septic patients. Personalized approaches (DynaCEL, HM-TARGET) generated patient-specific hemodynamic targets. While prospective studies showed a reduction in the duration of hypotension, evidence regarding the impact on mortality and organ failure remains limited. AI has the potential to improve the precision of hemodynamic monitoring and early intervention in the ICU; however, large-scale clinical trials are required to confirm its benefits on meaningful clinical outcomes.

Keywords: *artificial intelligence, hemodynamic monitoring, hypotension prediction, ICU, machine learning, predictive models*

PENDAHULUAN

Instabilitas hemodinamik merupakan salah satu determinan utama morbiditas dan mortalitas di *intensive care unit* (ICU) (Huygh et al., 2016; Monnet et al., 2025). Episode hipotensi, shock, dan gangguan perfusi jaringan yang tidak terdeteksi secara dini berkontribusi terhadap kejadian kegagalan organ, perpanjangan lama rawat, serta peningkatan risiko kematian (Schuurmans et al., 2024; Umegaki et al.,

2011). Secara global, 50–70% pasien ICU mengalami sedikitnya satu episode hipotensi, dan pemantauan kontinu menunjukkan banyak kasus hipotensi berat dengan durasi bermakna pada 24 jam pertama (Ghosh et al., 2016; Mathis et al., 2020). Durasi kumulatif hipotensi terbukti berhubungan secara dose response dengan mortalitas, gagal ginjal akut, dan disfungsi organ (Ackland & Abbott, 2022; B. Khwannimit et al., 2025; Rinehart et al.,

2019). Selain itu, 8–10% pasien ICU mengalami septic shock, dengan mortalitas ICU sekitar 35–40% (Abe et al., 2020; Imaeda et al., 2025), sementara beban sepsis global menunjukkan 30-day *mortality* sebesar 24% dan 90-day *mortality* sebesar 32%. Fakta ini menggarisbawahi keterbatasan pendekatan *monitoring* hemodinamik konvensional yang masih bersifat reaktif, sangat bergantung pada pengamatan visual, dan menggunakan sistem alarm ambang batas yang sering menimbulkan alarm fatigue serta gagal menangkap pola memburuknya status hemodinamik secara lebih progresif (Attique et al., 2025; Wang et al., 2023).

Perkembangan kecerdasan buatan atau *artificial intelligence* (AI), khususnya *machine learning* (ML) dan *deep learning*, telah menawarkan solusi untuk meningkatkan kemampuan deteksi dan prediksi dini ketidakstabilan hemodinamik (Chiang et al., 2025; Hadweh et al., 2025; Michard et al., 2025). Dalam satu dekade terakhir, literatur interdisipliner di bidang *critical care* menunjukkan peningkatan studi global, dengan sekitar 20–25% di antaranya berfokus pada prediksi hipotensi, kebutuhan vasopressor, atau risiko kegagalan sirkulasi (Chiang et al., 2025; Hadweh et al., 2025). Teknologi seperti *Hypotension prediction Index* (HPI), model prediksi berbasis *waveform* tekanan arteri, serta model ML multivariabel pada data ICU berskala besar telah menunjukkan performa prediktif yang kuat (Frassanito et al., 2022; Hatib et al., 2018; Bodin Khwannimit et al., 2025), dengan akurasi rata-rata *Area Under the Receiver Operating Characteristic curve* (AUROC) adalah 0,80–0,90 dalam memprediksi hipotensi 10–30 menit sebelum kejadian (Hatib et al., 2018; van der Ven et al., 2022). Beberapa studi prospektif melaporkan bahwa penerapan model prediktif berbasis AI dapat menurunkan durasi hipotensi intraoperatif dan *ICU-related hypotension* hingga 40–50%, menunjukkan potensi klinis teknologi ini untuk meningkatkan ketepatan intervensi

(Lai et al., 2024; Lorente et al., 2023; Yoshikawa et al., 2024).

Studi penelitian yang sudah terpublikasi menunjukkan bahwa bukti ilmiah yang tersedia masih belum konsisten dan cenderung terfragmentasi. Sebagian besar penelitian menggunakan desain retrospektif berbasis rekam medis elektronik atau analisis *waveform*, dengan lebih dari 60% studi terfokus pada tahap pengembangan dan validasi model tanpa menguji dampak nyata terhadap luaran klinis (Ackland & Abbott, 2022). Studi prospektif dan uji klinis masih terbatas, dengan proporsi kurang dari 15%, sementara *randomized controlled trials* yang mengevaluasi efektivitas implementasi hanya mencakup kurang dari 5% dari total literatur yang ada (Imaeda et al., 2025). Selain itu, sebagian besar penelitian lebih menitikberatkan pada metrik performa algoritma, seperti AUROC, sensitivitas, spesifisitas, dan kalibrasi model, daripada mengevaluasi luaran yang lebih bermakna secara klinis, termasuk mortalitas, cedera organ, kebutuhan terapi vasopressor, serta utilisasi sumber daya ICU (Chiang et al., 2025; Hatib et al., 2018; Michard et al., 2025).

Kesenjangan lain tampak pada kurangnya validasi eksternal, variabilitas tinggi antar-setting ICU, dan minimnya analisis mengenai tantangan implementasi seperti integrasi sistem, kesiapan perawat dan tenaga kesehatan, ketepatan waktu, serta risiko bias algoritmik (Umegaki et al., 2011; Yoshikawa et al., 2024). Banyak review sebelumnya juga menggabungkan konteks ruang operasi dan ICU tanpa memisahkan karakteristik fisiologi dan pola intervensi yang berbeda, sehingga memberikan gambaran yang kurang spesifik mengenai kegunaan AI untuk *monitoring* hemodinamik pada pasien kritis (Ackland & Abbott, 2022; Huygh et al., 2016). Beberapa ulasan literatur berfokus pada prediksi sepsis atau gagal napas dan bukan secara khusus pada hemodinamik, sehingga ruang bukti mengenai *AI-enhanced hemodynamic monitoring* masih belum tersintesis secara

komprehensif (Frassanito et al., 2022; Bodin Khwannimit et al., 2025). Pada zaman perkembangan teknologi sekarang, penerapan AI dalam *monitoring* hemodinamik memiliki signifikansi klinis yang substansial. Kemampuan untuk mengidentifikasi pola perubahan tekanan darah, variabilitas detak jantung, respons vaskular, serta dinamika perfusi memungkinkan pendekatan yang lebih prediktif dalam manajemen pasien kritis (Chiang et al., 2025; Lorente et al., 2023). Integrasi AI tidak hanya berpotensi meningkatkan akurasi deteksi dini, tetapi juga mengubah paradigma perawatan ICU dari *reactive monitoring* menjadi *predictive and anticipatory monitoring*. Sintesis bukti ilmiah terkini sangat diperlukan untuk memahami sejauh mana teknologi ini dapat meningkatkan keselamatan pasien, membantu pengambilan keputusan klinis, dan mengurangi beban kerja tenaga kesehatan. Berdasarkan kebutuhan tersebut, *systematic review* ini bertujuan mengevaluasi secara komprehensif bukti ilmiah mengenai penggunaan kecerdasan buatan dalam meningkatkan *monitoring* hemodinamik di ICU, meliputi jenis algoritma yang digunakan, performa prediktif, serta dampaknya terhadap luaran klinis yang relevan.

TUJUAN PENELITIAN

Tujuan penelitian *systematic review* ini bertujuan mengevaluasi secara komprehensif bukti ilmiah mengenai penggunaan kecerdasan buatan dalam meningkatkan *monitoring* hemodinamik di ICU, meliputi jenis algoritma yang digunakan, performa prediktif, serta dampaknya terhadap luaran klinis yang relevan.

METODE PENELITIAN

Desain Studi

Studi *systematic review* yang mengikuti pedoman Preferred Reporting Items for *Systematic review s* and Meta-Analyses (PRISMA) tahun 2020 (Parums, 2021), yang bertujuan untuk mensintesis

bukti terkini mengenai penerapan kecerdasan buatan (AI) dalam meningkatkan *monitoring* hemodinamik di ICU pada populasi dewasa. Mengingat adanya heterogenitas pada model AI, algoritma prediksi, jenis data masukan, dan luaran klinis yang dievaluasi, studi ini menggunakan pendekatan sintesis naratif.

Search Strategy

Pencarian literatur dilakukan pada enam basis data utama, yaitu CINAHL, Cochrane, Embase, PubMed, Scopus, dan Web of Science, serta tambahan pencarian dari grey literature melalui Google Scholar dan penelusuran artikel pada laman web ilmiah relevan. Strategi pencarian dikembangkan berdasarkan empat kelompok kata kunci utama, yaitu kecerdasan buatan, *monitoring* hemodinamik, unit perawatan intensif, dan algoritma prediktif serta luaran klinis. Kata kunci yang digunakan mencakup istilah (“*artificial intelligence*” OR AI OR “*machine learning*” OR “*deep learning*” OR “*neural network**” OR “*predictive modelling*” OR “*algorithmic prediction*”) AND (“*hemodynamic monitoring*” OR “*blood pressure monitoring*” OR “*arterial waveform analysis*” OR “*hemodynamic instability*” OR “*hypotension prediction*”) AND (“*intensive care unit*” OR ICU OR “*critical care*” OR “*intensive therapy unit*” OR “*high-dependency unit*”) AND (“*predictive algorithms*” OR “*prediction model**” OR “*early warning system**” OR “*risk prediction tool**” OR “*clinical outcome**” OR *mortality* OR *morbidity* OR “*organ dysfunction*” OR “*vasopressor requirement*”). Kata kunci tersebut dikombinasikan menggunakan *Boolean operator*, dan pencarian dilakukan pada bagian judul, abstrak, dan kata kunci (*title, abstract, keywords*) di setiap basis data tanpa pembatasan tahun publikasi. Seluruh *keywords* pencarian dan sintaks lengkap untuk setiap basis data tercantum pada *supplementary file*.

Kriteria kelayakan

Kriteria kelayakan studi ditetapkan berdasarkan kerangka PICOS

(*supplementary file*). Population adalah pasien dewasa berusia ≥ 18 tahun yang menjalani perawatan di ICU, meliputi ICU umum, bedah, medikal, maupun jantung. *Intervention* yang dievaluasi mencakup penerapan AI, termasuk *machine learning* dan *deep learning*, yang digunakan untuk meningkatkan *monitoring* hemodinamik. Teknologi ini dapat berupa model prediksi hipotensi, kebutuhan *vasopressor*, *shock*, atau gangguan perfusi dengan memanfaatkan data fisiologis kontinu, seperti *waveform* arteri, tekanan darah, elektrokardiografi, dan tanda vital, maupun data rekam medis elektronik. *Comparison* dalam studi dapat berupa *monitoring* hemodinamik konvensional, termasuk penggunaan skor risiko tradisional, atau studi yang tidak menyertakan kelompok pembandingan. *Outcomes* yang dipertimbangkan meliputi dua kategori, yaitu luaran klinis, seperti insidensi dan durasi hipotensi, mortalitas ICU, cedera organ, kebutuhan atau *dosis vasopressor*, lama rawat ICU, serta kejadian komplikasi hemodinamik, dan luaran performa model, termasuk AUROC, akurasi, sensitivitas, spesifisitas, kalibrasi, serta waktu antisipasi atau *lead time prediction*. *Study Design* yang diikutsertakan mencakup *randomized controlled trials*, studi prospektif baik observasional maupun intervensi, kohort retrospektif, desain *quasi-experimental*, serta studi pengembangan model atau penelitian berbasis *research and development* yang berhubungan langsung dengan penggunaan AI dalam pemantauan hemodinamik di ICU.

Seleksi Studi

Pencarian literatur menghasilkan total 8.759 artikel dari enam basis data utama. Pada tahap awal, sebanyak 2.271 artikel duplikat dihapus, kemudian 538 artikel dikeluarkan karena tidak menyediakan informasi referensi secara lengkap, serta 1 artikel dikeluarkan karena retracted. Setelah proses penyaringan judul dan abstrak, hanya 1.178 artikel yang memenuhi kriteria inklusi awal dan dilanjutkan untuk ditelaah pada tahap teks lengkap. Pada tahap ini, studi

yang tidak relevan dengan kerangka PICOS, tidak menggunakan kecerdasan buatan sebagai intervensi utama, atau tidak melaporkan luaran hemodinamik yang diperlukan dikeluarkan. Secara keseluruhan, 16 artikel memenuhi kriteria dan diikutsertakan dalam proses ekstraksi data. Seluruh proses identifikasi, penyaringan, penilaian kelayakan, dan inklusi studi dilaporkan menggunakan pedoman PRISMA, sebagaimana ditampilkan pada Gambar 1.

Ekstraksi Data

Ekstraksi data dilakukan secara mandiri mengekstraksi informasi utama dari setiap artikel yang memenuhi kriteria inklusi, meliputi: karakteristik studi (nama penulis, tahun publikasi, negara, desain penelitian), karakteristik populasi (jenis ICU, jumlah sampel, karakteristik demografis), rincian intervensi kecerdasan buatan (jenis algoritma, sumber dan jenis data input, horizon prediksi, variabel prediktor), jenis pembandingan yang digunakan, serta luaran yang dilaporkan. Luaran yang diekstraksi mencakup luaran klinis (insidensi dan durasi hipotensi, mortalitas, cedera organ, kebutuhan dan dosis vasopressor, lama rawat ICU, serta komplikasi hemodinamik) dan luaran performa model (AUROC, akurasi, sensitivitas, spesifisitas, PPV/NPV, kalibrasi, dan lead time prediksi). Setiap perbedaan hasil ekstraksi antara penelaah diselesaikan melalui diskusi atau dengan melibatkan penelaah ketiga.

Asesmen Resiko Bias

Penilaian risiko bias dilakukan dengan menggunakan alat *critical appraisal* dari Joanna Briggs Institute (JBI) yang disesuaikan dengan desain masing-masing studi. Dua penelaah secara independen menilai kualitas metodologis setiap artikel berdasarkan sejumlah domain, seperti kejelasan kriteria inklusi, kesesuaian desain dan metode, kualitas pengukuran paparan dan luaran, potensi faktor perancu, kejelasan pelaporan, serta kecukupan analisis statistik. Setiap item dinilai sebagai “ya”, “tidak”, “tidak jelas”, atau “tidak diterapkan”. Hasil

penilaian kemudian digunakan untuk mengklasifikasikan tingkat risiko bias (rendah, sedang, atau tinggi) dan dipertimbangkan dalam interpretasi hasil.

Sintesis Data

Hasil studi menunjukkan terdapat heterogenitas yang cukup besar pada desain penelitian, jenis algoritma AI, sumber data, horizon prediksi, serta luaran klinis yang dilaporkan, data tidak digabungkan dalam bentuk meta-analisis kuantitatif. Sintesis data dilakukan dengan sintesis naratif dengan pendekatan tematik. Studi dikelompokkan berdasarkan jenis algoritma dan tujuan prediksi, kemudian disajikan dalam table ringkasan untuk mempermudah perbandingan. Hasil utama dari setiap studi, termasuk ukuran performa model dan luaran klinis, dideskripsikan dan dibandingkan secara kualitatif, dengan mempertimbangkan konteks klinis, kualitas metodologis, dan risiko bias. Temuan-temuan ini kemudian diintegrasikan untuk mengidentifikasi pola umum, keterbatasan bukti, serta implikasi klinis dan penelitian lebih lanjut terkait penggunaan kecerdasan buatan sebagai pendukung *monitoring* hemodinamik di ICU.

HASIL DAN PEMBAHASAN

Karakteristik Studi

Pencarian dan proses seleksi menghasilkan total 16 studi yang memenuhi kriteria inklusi, studi tersebut terdiri dari penelitian pengembangan model, validasi internal dan eksternal (Azam & Singh, 2025; Chiang et al., 2025; Meng et al., 2025; Moghadam et al., 2020; Rahman et al., 2021; Sun et al., 2025; Wu et al., 2024), evaluasi prospektif (B. Khwannimit et al., 2025), studi observasional cohort (Chiang et al., 2025; Meng et al., 2025; Sun et al., 2025), serta *randomized control and trial* (Rellum et al., 2023). Studi mencakup algoritma AI yang beragam, mulai dari *ensemble learning*, *gradient boosting*, XGBoost, *recurrent neural networks*, *model time-varying*, hingga *reinforcement learning* dan pemetaan risiko hemodinamik berbasis kernel density estimation. Studi telah

dilaksanakan pada populasi ICU di berbagai negara termasuk Amerika Serikat (Azam & Singh, 2025; Meng et al., 2025; Rahman et al., 2021), Taiwan (Chiang et al., 2025; Dung-Hung et al., 2022), China (Wu et al., 2024), Thailand (B. Khwannimit et al., 2025), Jepang (Sun et al., 2025), Netherlands (Rellum et al., 2023), dan beberapa basis data multicenter internasional.

Sebagian besar studi merupakan studi retrospektif berbasis big-data ICU, memanfaatkan database besar seperti eICU, MIMIC-III, dan MIMIC-IV (Azam & Singh, 2025; Chiang et al., 2025; Rahman et al., 2021). Beberapa studi lainnya menggunakan data prospektif atau uji klinis (B. Khwannimit et al., 2025; Rellum et al., 2023). Sebagian besar studi meneliti pasien dewasa di ICU dengan berbagai kondisi kritis, termasuk syok sepsis, kebutuhan vasopressor, risiko gagal organ, serta populasi *postoperative cardiac surgery*.

Tipe Model Artificial intelligence

1) Model Multivariabel (HSI, Extended HSI, Gradient Boosting Models)

HSI adalah model *ensemble decision trees* yang menggunakan 33 variabel klinis. Rahman menunjukkan bahwa HSI memiliki performa prediksi tinggi untuk intervensi hemodinamik 1 jam sebelumnya, dengan hasil lebih baik dibanding parameter tunggal seperti SBP dan shock index (Rahman et al., 2021). Temuan ini diperkuat oleh validasi eksternal di Taiwan (Chiang et al., 2025), dengan AUROC 0,76. Ekstensi ke ED/ICU (Wu et al., 2024) menunjukkan bahwa model ini juga dapat memprediksi delayed septic shock, menunjukkan fleksibilitas lintas setting.

2) Time-varying and Sequential Deep learning Models (TvHEWS, Bi-LSTM)

Model TvHEWS menggunakan 24 model XGBoost yang diperbarui tiap jam, menghasilkan sistem *early warning* dengan kemampuan prediksi hingga 7 jam sebelum intervensi hemodinamik (Chiang et al., 2025). Model ini menunjukkan performa

konsisten di berbagai cohort, termasuk validasi eksternal.

Model Bi-LSTM dengan attention mampu memprediksi kebutuhan vasopressor dalam 24 jam pertama perawatan ICU. Variabel seperti MAP dan HR muncul sebagai penentu penting dalam pemodelan sekuensial.

3. *Waveform -based Prediction* (HPI and derivatives)

HPI digunakan dalam beberapa studi, baik observasional maupun RCT. HPI secara konsisten mampu memprediksi hipotensi beberapa menit sebelum onset (biasanya 5–15 menit), bahkan pada pasien *septic shock* (B. Khwannimit et al., 2025). Studi RCT mempelajari peran HPI dalam protokol terapi hemodinamik berbasis prediksi (Rellum et al., 2023; Runge et al., 2023).

4. *Personalized Hemodynamic Targets* (DynaCEL, HM-TARGET)

DynaCEL menghasilkan target individual untuk HR dan SBP yang terkait risiko mortalitas 24 jam; pasien yang berada dalam $\pm 20\%$ dari target menunjukkan penurunan risiko kematian. HM-TARGET memetakan zona risiko HR–BP secara real-time, membantu menentukan *hemodynamic safe ranges* (Meng et al., 2025; Sun et al., 2025).

Predictive Performance

Secara keseluruhan, sebagian besar model kecerdasan buatan yang dianalisis dalam studi menunjukkan kinerja prediktif yang tinggi, dengan nilai AUROC yang umumnya berada pada rentang 0,76 hingga 0,95, tergantung pada jenis algoritma, sumber data, serta luaran yang diprediksi. Temuan ini menegaskan bahwa AI memiliki potensi yang substansial untuk meningkatkan kemampuan deteksi dini ketidakstabilan hemodinamik dibandingkan metode pemantauan konvensional.

Model *Hemodynamic Stability Index* (HSI) konsisten menunjukkan performa kuat dalam memprediksi kebutuhan intervensi hemodinamik, seperti pemberian vasopressor, bolus cairan besar, atau transfuse (Chiang et al., 2025; Rahman et

al., 2021). Pada berbagai dataset besar multicenter, HSI menghasilkan AUROC tinggi dan secara signifikan mengungguli parameter tradisional seperti *systolic blood pressure* dan *shock index* (Rahman et al., 2021; Wu et al., 2024). Kinerja robust ini juga direplikasi dalam validasi eksternal, menandakan generalisasi model yang baik di berbagai setting ICU.

Model *Time-varying Hemodynamic Early Warning Score* (TvHEWS) menunjukkan performa prediksi yang sangat kompetitif, bahkan menjadi salah satu yang paling stabil di antara model AI yang ada (Chiang et al., 2025). Penggunaannya pada beberapa cohort independen memperlihatkan bahwa TvHEWS mampu mempertahankan AUROC tinggi dan AUPRC yang baik, sekaligus meminimalkan frekuensi *false alarms* dan *missed events*. Keunggulan stabilitas antar-cohort ini penting untuk penerapan klinis karena menunjukkan ketahanan model terhadap variasi karakteristik populasi dan dinamika aliran data ICU.

Sementara itu, *Hypotension prediction Index* (HPI), model berbasis analisis *waveform* tekanan arteri, memperlihatkan nilai AUROC antara 0,90 hingga 0,97 dalam berbagai studi (B. Khwannimit et al., 2025; Rellum et al., 2023; Runge et al., 2023). HPI terbukti efektif mendeteksi hipotensi yang akan terjadi dalam 5–15 menit sebelum onset, termasuk pada populasi yang kompleks seperti pasien dengan syok sepsis di ICU (Runge et al., 2023). Keunggulan ini menjadikan HPI sebagai salah satu model prediksi hipotensi paling presisi yang tersedia saat ini.

Model Bi-LSTM dengan mekanisme attention, yang dirancang untuk memproses data sekuensial ICU, memperlihatkan AUROC sekitar 0,83 untuk prediksi kebutuhan vasopressor dalam 24 jam pertama perawatan (Lorente et al., 2023; Mathis et al., 2020). Temuan ini menggarisbawahi kemampuan model *deep learning* dalam menangkap pola temporal yang tidak dapat ditangkap dengan baik oleh algoritma tradisional.

Algoritma *machine learning* berbasis riwayat fisiologis jangka pendek mampu memprediksi kejadian hipotensi dengan baik, menunjukkan bahwa bahkan model berbasis fitur fisiologis minimalis dapat memberikan nilai prediktif yang signifikan jika dilatih dengan pendekatan label dinamis yang meniru kondisi real-time *monitoring* (Moghadam et al., 2020). Pada model prediksi tekanan darah (*BP prediction models*), algoritma ensemble seperti *gradient boosting* dan XGBoost berhasil memenuhi standar akurasi AAMI dalam evaluasi internal (Schoormans et al., 2024; van der Ven et al., 2022). Namun, performanya menurun saat diuji pada dataset eksternal, menunjukkan tantangan klasik dalam penerapan AI, yaitu penurunan generalisasi ketika model dihadapkan pada variasi antar-institusi atau distribusi data yang berbeda.

Secara keseluruhan, seluruh model AI yang dievaluasi memperlihatkan peningkatan yang konsisten dalam hal ketepatan, sensitivitas, serta kemampuan prediksi jangka pendek maupun menengah ketika dibandingkan dengan metode konvensional seperti *threshold MAP* atau *shock index* (Chiang et al., 2025; Dung-Hung et al., 2022). Temuan ini mengindikasikan bahwa AI mampu menangkap pola hemodinamik kompleks yang tidak dapat dideteksi melalui pendekatan pemantauan linear atau nilai ambang sederhana, sehingga berpotensi besar meningkatkan ketepatan respons klinis terhadap instabilitas hemodinamik di ICU.

Clinical and Operational Outcomes

Hanya sebagian studi yang menilai dampak klinis langsung dari penggunaan AI dalam *monitoring* hemodinamik, namun temuan yang tersedia menunjukkan beberapa manfaat penting. Penggunaan HPI dalam konteks operasi jantung maupun non-jantung secara konsisten memperlihatkan pengurangan durasi dan frekuensi hipotensi, yang relevan karena stabilitas hemodinamik perioperatif berpengaruh pada kondisi pasien saat memasuki ICU (Rellum et al., 2023; Runge et al., 2023). Efektivitas serupa

juga ditemukan pada pasien syok sepsis di ICU, menunjukkan bahwa kemampuan prediktif HPI tetap kuat pada populasi kritis yang lebih kompleks (B. Khwannimit et al., 2025). Pada level sistem peringatan dini, TvHEWS menunjukkan performa yang stabil pada berbagai dataset dan kondisi klinis, dengan penurunan *false alarms* dan *missed events* (Chiang et al., 2025). Kinerja ini penting untuk meningkatkan keandalan alarm dan mengurangi beban kerja klinisi dalam lingkungan ICU yang padat. Beberapa studi juga menyoroti peran AI dalam personalisasi terapi hemodinamik. Model seperti DynaCEL dan HM-TARGET mampu mengidentifikasi zona aman kombinasi tekanan darah dan frekuensi jantung yang spesifik untuk tiap pasien, sehingga mendukung pendekatan *precision hemodynamic s* yang lebih adaptif terhadap kondisi klinis individual (Meng et al., 2025; Sun et al., 2025). Dari aspek implementasi, studi Delphi oleh Rahman et al. membantu merumuskan outcome klinis yang relevan seperti kebutuhan vasopressor, bolus cairan, atau transfuse sebagai parameter evaluasi model prediksi hemodinamik. Hal ini memberikan dasar penting bagi penerapan model seperti HSI dan TvHEWS dalam praktik klinis, terutama untuk memastikan kesesuaian model dengan kebutuhan pengambilan keputusan di ICU (Chiang et al., 2025; Dung-Hung et al., 2022; Rahman et al., 2021).

KESIMPULAN

Hasil *systematic review* ini menunjukkan bahwa kecerdasan buatan memiliki potensi signifikan dalam meningkatkan deteksi dan prediksi dini ketidakstabilan hemodinamik pada pasien ICU. Model multivariabel seperti HSI, pendekatan time-varying seperti TvHEWS, serta model berbasis *waveform* seperti HPI secara konsisten menunjukkan performa prediksi yang tinggi dan mampu mengidentifikasi risiko hipotensi atau kebutuhan vasopressor sebelum kejadian terjadi. Pendekatan personalisasi yang dikembangkan melalui DynaCEL dan HM-

TARGET juga membuka peluang untuk terapi hemodinamik yang lebih adaptif dan spesifik bagi individu. Meskipun demikian, sebagian besar studi masih berada pada tahap pengembangan atau validasi model, dengan sedikit penelitian prospektif atau uji klinis yang mengevaluasi dampak nyata terhadap luaran klinis. Oleh karena itu, diperlukan penelitian lebih lanjut yang berfokus pada implementasi klinis dan manfaat jangka panjang untuk memastikan efektivitas AI dalam praktik perawatan intensif.

PENGAKUAN / Acknowledgement

Terima kasih diucapkan kepada semua pihak yang telah membantu dalam pelaksanaan penelitian ini.

DAFTAR PUSTAKA

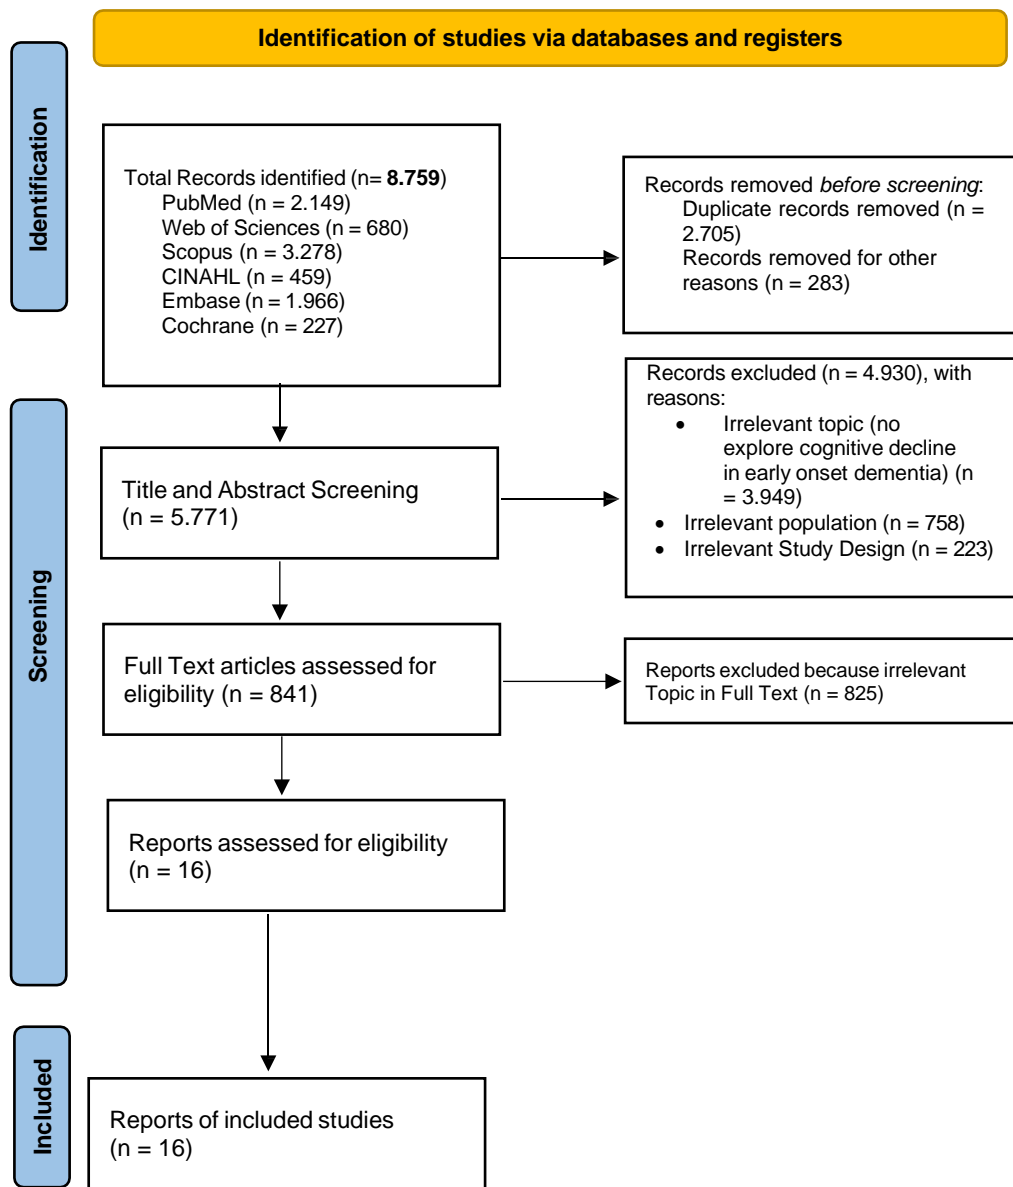
- Abe, T., Yamakawa, K., Ogura, H., Kushimoto, S., Saitoh, D., Fujishima, S., Otomo, Y., Kotani, J., Umemura, Y., Sakamoto, Y., Sasaki, J., Shiino, Y., Takeyama, N., Tarui, T., Shiraishi, S. I., Tsuruta, R., Nakada, T. A., Hifumi, T., Hagiwara, A. Gando, S. (2020). Epidemiology of sepsis and septic shock in intensive care unit s between sepsis-2 and sepsis-3 populations: sepsis prognostication in *intensive care unit* and emergency room (SPICE-ICU). *J Intensive Care*, 8, 44. <https://doi.org/10.1186/s40560-020-00465-0>
- Ackland, G. L., & Abbott, T. E. F. (2022). Hypotension as a marker or mediator of perioperative organ injury: a narrative review. *Br J Anaesth*, 128(6), 915-930. <https://doi.org/10.1016/j.bja.2022.01.012>
- Attique, Z., Abusannuga, M., Abdulla, S., Zulfiqar, H., Almohannadi, M., & Shajahan, F. (2025). Advanced *Hemodynamic Monitoring* : Pros, Cons, and the Future. In N. Shaikh (Ed.), *Hemodynamic s and Hemodynamic Monitoring* . *IntechOpen*. <https://doi.org/10.5772/intechopen.1011933>
- Azam, M., & Singh, S. (2025). *Clinical-Grade Blood pressure Prediction in ICU Settings: An Ensemble Framework with Uncertainty Quantification and Cross-Institutional Validation*. <https://doi.org/10.48550/arXiv.2507.19530>
- Chiang, D.-H., Jiang, Z., Tian, C., & Wang, C.-Y. (2025). Development and validation of a dynamic early warning system with time-varying machine learning models for predicting hemodynamic instability in critical care : a multicohort study. *Critical care* , 29(1), 318. <https://doi.org/10.1186/s13054-025-05553-x>
- Dung-Hung, C., Cong, T., Zeyu, J., Yu-Shan, O. Y., & Yung-Yan, L. (2022). External validation of a machine learning model to predict hemodynamic instability in intensive care unit . *Crit Care*, 26(1), 215. <https://doi.org/10.1186/s13054-022-04088-9>
- Frassanito, L., Giuri, P. P., Vassalli, F., Piersanti, A., Longo, A., Zanfini, B. A., Catarci, S., Fagotti, A., Scambia, G., & Draisci, G. (2022). Hypotension prediction Index with non-invasive continuous arterial pressure waveform s (ClearSight): clinical performance in Gynaecologic Oncologic Surgery. *Journal of Clinical Monitoring and Computing*, 36(5), 1325-1332. <https://doi.org/10.1007/s10877-021-00763-4>
- Ghosh, S., Feng, M., Nguyen, H., & Li, J. (2016). Hypotension Risk Prediction via Sequential Contrast Patterns of ICU Blood pressure . *IEEE J Biomed Health Inform*, 20(5), 1416-1426. <https://doi.org/10.1109/jbhi.2015.2453478>
- Hadweh, P., Niset, A., Salvagno, M., Al Barajraji, M., El Hadwe, S., Taccone,

- F. S., & Barrit, S. (2025). Machine learning and Artificial intelligence in Intensive Care Medicine: Critical Recalibrations from Rule-Based Systems to Frontier Models. *Journal of Clinical Medicine*, 14(12), 4026.
- Hatib, F., Jian, Z., Buddi, S., Lee, C., Settels, J., Sibert, K., Rinehart, J., & Cannesson, M. (2018). Machine-learning Algorithm to Predict Hypotension Based on High-fidelity Arterial Pressure Waveform Analysis. *Anesthesiology*, 129(4), 663-674.
<https://doi.org/10.1097/aln.00000000000002300>
- Huygh, J., Peeters, Y., Bernards, J., & Malbrain, M. L. (2016). *Hemodynamic monitoring in the critically ill: an overview of current cardiac output monitoring methods*. F1000Res, 5.
<https://doi.org/10.12688/f1000research.8991.1>
- Imaeda, T., Oami, T., Yokoyama, T., Nakagawa, S., Ogura, H., Shime, N., Umemura, Y., Matsushima, A., Fushimi, K., & Nakada, T. A. (2025). Epidemiology and outcomes of septic shock in Japan: a nationwide retrospective cohort study from a medical claims database by the Japan Sepsis Alliance (JaSA) study group. *Crit Care*, 29(1), 309.
<https://doi.org/10.1186/s13054-025-05556-8>
- Khwannimit, B., Sathaporn, N., & Vattanavanit, V. (2025). Ability of the Hypotension prediction Index to predict hypotension in patients with septic shock in the intensive care unit. *Scientific Reports*, 15(1), 40478.
<https://doi.org/10.1038/s41598-025-24270-7>
- Khwannimit, B., Sathaporn, N., & Vattanavanit, V. (2025). Ability of the Hypotension prediction Index to predict hypotension in patients with septic shock in the intensive care unit . *Sci Rep*, 15(1), 40478.
<https://doi.org/10.1038/s41598-025-24270-7>
- Lai, C. J., Cheng, Y. J., Han, Y. Y., Hsiao, P. N., Lin, P. L., Chiu, C. T., Lee, J. M., Tien, Y. W., & Chien, K. L. (2024). Hypotension prediction Index for prevention of intraoperative hypotension in patients undergoing general anesthesia: a randomized controlled trial. *Perioper Med (Lond)*, 13(1), 57.
<https://doi.org/10.1186/s13741-024-00414-7>
- Lorente, J. V., Ripollés-Melchor, J., Jiménez, I., Becerra, A. I., Mojarro, I., Fernández-Valdes-Bango, P., Fuentes, M. A., Moreno, A., Agudelo, M. E., Villar-Pellit de la Vega, A., Ruiz-Escobar, A., Cortés, A., Venturoli, R., Quintero, A., Acedo, G. M., Abad-Motos, A., Gómez, P., Abad-Gurumeta, A., & Monge-García, M. I. (2023). Intraoperative hemodynamic optimization using the Hypotension prediction Index vs. goal-directed hemodynamic therapy during elective major abdominal surgery: the Predict-H multicenter randomized controlled trial [Original Research]. *Frontiers in Anesthesiology*, Volume 2 - 2023.
<https://doi.org/10.3389/fanes.2023.1193886>
- Mathis, M. R., Naik, B. I., Freundlich, R. E., Shanks, A. M., Heung, M., Kim, M., Burns, M. L., Colquhoun, D. A., Rangrass, G., Janda, A., Engoren, M. C., Saager, L., Tremper, K. K., Kheterpal, S., Aziz, M. F., Coffman, T., Durieux, M. E., Levy, W. J., Schonberger, R. B., Wedeven, C. (2020). Preoperative Risk and the Association between Hypotension and Postoperative Acute Kidney Injury. *Anesthesiology*, 132(3), 461-475.
<https://doi.org/10.1097/aln.00000000000003063>
- Meng, L., Li, J., Liu, X., Sun, Y., Li, Z., Cai, J., Parab, A. D., Lu, G., Budhkar,

- A., Kanakasabai, S., Adams, D. C., Liu, Z., Zhang, X., & Su, J. (2025). Personalized and real time hemodynamic management in critical care using Dynamic Cohort Ensemble Learning (DynaCEL). *NPJ Digit Med*, 8(1), 474. <https://doi.org/10.1038/s41746-025-01863-0>
- Michard, F., Mulder, M. P., Gonzalez, F., & Sanfilippo, F. (2025). AI for the hemodynamic assessment of critically ill and surgical patients: focus on clinical applications. *Ann Intensive Care*, 15(1), 26. <https://doi.org/10.1186/s13613-025-01448-w>
- Moghadam, M. C., Abad, E. M. K., Bagherzadeh, N., Ramsingh, D., Li, G.-P., & Kain, Z. N. (2020). A machine-learning approach to predicting hypotensive events in ICU settings. *Computers in Biology and Medicine*, 118, 103626. <https://doi.org/https://doi.org/10.1016/j.compbiomed.2020.103626>
- Monnet, X., Messina, A., Greco, M., Bakker, J., Aissaoui, N., Cecconi, M., Coppalini, G., De Backer, D., Edul, V. K., Evans, L., Hernández, G., Hunsicker, O., Ince, C., Kaufmann, T., Levy, B., Malbrain, M., Mebazaa, A., Myatra, S. N., Ostermann, M., Chew, M. S. (2025). ESICM guidelines on circulatory shock and hemodynamic monitoring 2025. *Intensive Care Med*, 51(11), 1971-2012. <https://doi.org/10.1007/s00134-025-08137-z>
- Parums, D. V. (2021). Review articles, systematic reviews, meta-analysis, and the updated preferred reporting items for systematic reviews and meta-analyses (PRISMA) 2020 guidelines. *Medical science monitor: international medical journal of experimental and clinical research*, 27, e934475-934471.
- Rahman, A., Chang, Y., Dong, J., Conroy, B., Natarajan, A., Kinoshita, T., Vicario, F., Frassica, J., & Xu-Wilson, M. (2021). Early prediction of hemodynamic Interventions in the intensive care unit using machine learning. *Critical care*, 25(1), 388. <https://doi.org/10.1186/s13054-021-03808-x>
- Rellum, S. R., Schuurmans, J., Schenk, J., van der Ster, B. J. P., van der Ven, W. H., Geerts, B. F., Hollmann, M. W., Cherpanath, T. G. V., Lagrand, W. K., Wynandts, P., Paulus, F., Driessen, A. H. G., Terwindt, L. E., Eberl, S., Hermanns, H., Veelo, D. P., & Vlaar, A. P. J. (2023). Effect of the machine learning-derived Hypotension prediction Index (HPI) combined with diagnostic guidance versus standard care on depth and duration of intraoperative and postoperative hypotension in elective cardiac surgery patients: HYPE-2 – study protocol of a randomised clinical trial. *BMJ Open*, 13(5), e061832. <https://doi.org/10.1136/bmjopen-2022-061832>
- Rinehart, J., Ma, M., Calderon, M. D., Bardaji, A., Hafiane, R., Van der Linden, P., & Joosten, A. (2019). Blood pressure variability in surgical and intensive care patients: Is there a potential for closed-loop vasopressor administration? *Anaesth Crit Care Pain Med*, 38(1), 69-71. <https://doi.org/10.1016/j.accpm.2018.11.009>
- Runge, J., Graw, J., Grundmann, C. D., Komanek, T., Wischermann, J. M., & Frey, U.H. (2023). Hypotension prediction Index and Incidence of Perioperative Hypotension: A Single-Center Propensity-Score-Matched Analysis. *Journal of Clinical Medicine*, 12(17), 5479.
- Schuurmans, J., van Rossem, B. T. B., Rellum, S. R., Tol, J. T. M., Kurucz, V. C., van Mourik, N., van der Ven, W. H., Veelo, D. P., Schenk, J., & Vlaar, A. P. J. (2024). Hypotension

- during intensive care stay and mortality and morbidity : a systematic review and meta-analysis. *Intensive Care Med*, 50(4), 516-525. <https://doi.org/10.1007/s00134-023-07304-4>
- Sun, Y., Li, J., Liu, X., Mortensen, G. A., Gu, X., Adams, D. C., Tang, H., Su, J., Liu, Z., Sun, D., & Meng, L. (2025). The HM-TARGET personalised real-time haemodynamic targets in critical care . *Nature Communications*, 16(1), 7307. <https://doi.org/10.1038/s41467-025-62527-x>
- Umegaki, T., Ikai, H., & Imanaka, Y. (2011). The impact of acute organ dysfunction on patients' mortality with severe sepsis. *J Anaesthesiol Clin Pharmacol*, 27(2), 180-184. <https://doi.org/10.4103/0970-9185.81816>
- van der Ven, W. H., Terwindt, L. E., Risvanoglu, N., Ie, E. L. K., Wijnberge, M., Veelo, D. P., Geerts, B. F., Vlaar, A. P. J., & van der Ster, B. J. P. (2022). Performance of a machine-learning algorithm to predict hypotension in mechanically ventilated patients with COVID-19 admitted to the intensive care unit : a cohort study. *J Clin Monit Comput*, 36(5), 1397-1405. <https://doi.org/10.1007/s10877-021-00778-x>
- Wang, L., He, W., Chen, Y., Wu, Q., Du, X., Li, Q., & Song, C. (2023). Intensive care unit nurses' perceptions and practices regarding clinical alarms: A descriptive study. *Nurs Open*, 10(8), 5531-5540. <https://doi.org/10.1002/nop2.1792>
- Wu, M., Li, S., Yu, H., Jiang, C., Dai, S., Jiang, S., & Zhao, Y. (2024). Extension of an ICU-based noninvasive model to predict latent shock in the emergency department: an exploratory study. *Front Cardiovasc Med*, 11, 1508766. <https://doi.org/10.3389/fcvm.2024.1508766>
- 8766
Yoshikawa, Y., Maeda, M., Kunigo, T., Sato, T., Takahashi, K., Ohno, S., Hirahata, T., & Yamakage, M. (2024). Effect of using Hypotension prediction Index versus conventional goal-directed haemodynamic management to reduce intraoperative hypotension in non-cardiac surgery: A randomised controlled trial. *J Clin Anesth*, 93, 111348. <https://doi.org/10.1016/j.jclinane.2023.111348>

Lampiran Gambar



Gambar 1. PRISMA Diagram *Systematic review*