



Recibido: 2026-07-31

Aceptado: 2026-08-14

Publicado: 2026-09-02

Protocolo internacional “Resc-IA-Sepsis”: un sistema de aprendizaje por refuerzo para la intervención quirúrgica multidisciplinaria y guiado por biomarcadores en choque séptico y falla multiorgánica

International “Resc-IA-Sepsis” protocol: a reinforcement learning system for multidisciplinary surgical intervention guided by biomarkers in septic shock and multiorgan failure

Autores

Alba Verónica Pullaguari Quizhpe¹

<https://orcid.org/0009-0000-5881-5112>

averonicapq@gmail.com

Universidad Técnica Particular de Loja

Loja – Ecuador

Diego Roberto Orrala Mendoza²

<https://orcid.org/0009-0009-2778-6334>

diegoorralam@outlook.com

Investigador Independiente

Guayaquil – Ecuador

Jhonnatan Patricio Guilcapi López³

<https://orcid.org/0009-0002-4331-8257>

guilcapi.jonatan1469@gmail.com

Médico Residente - Hospital del Día

Maria Auxiliadora

Riobamba – Ecuador

Luis Andrés Sosa Mena⁴

Médico general en funciones hospitalarias,
servicio Pediatría

<https://orcid.org/0009-0001-0520-645X>

mdsosandres@gmail.com

Hospital Gineco Obstetrico Pediatrico de

Nueva Aurora Luz Elena Arismendi

Quito – Ecuador

José Luis Ordóñez Galiano⁵

<https://orcid.org/0009-0008-1868-6924>

jlog21@hotmail.com

Médico Asistencial. Clínica los Pinos

Quito – Ecuador

Resumen

Introducción: El choque séptico y la falla multiorgánica representan las complicaciones más graves de la sepsis, con una mortalidad que oscila entre el 28% y el 50% según las series reportadas (He et al., 2026). Los sistemas de apoyo a la decisión clínica basados en inteligencia artificial han emergido como herramientas prometedoras para optimizar el manejo de estos pacientes críticos (MORE-CLEAR, 2026). El aprendizaje por refuerzo (RL), en particular, ofrece un marco para la toma de decisiones secuenciales en entornos dinámicos como las unidades de cuidados intensivos (rECMOmender, 2026). **Objetivo:** Describir el protocolo internacional "Resc-IA-Sepsis", un sistema de aprendizaje por refuerzo para la intervención quirúrgica multidisciplinaria guiada por biomarcadores en choque séptico y falla multiorgánica. **Metodología:** Revisión sistemática de la literatura siguiendo las guías PRISMA 2020 (Page et al., 2021). Se realizó una búsqueda en PubMed, LILACS, SciELO y Cochrane para estudios publicados entre 2020 y 2026 sobre sistemas de aprendizaje por refuerzo en sepsis, modelos predictivos de falla orgánica y biomarcadores en choque séptico. **Resultados:** Se identificaron 7 estudios relevantes que documentan la aplicación de RL y modelos de machine learning en sepsis. Los modelos de RL han demostrado capacidad para optimizar decisiones terapéuticas, con sistemas como MORE-CLEAR que integran datos estructurados y notas clínicas para mejorar la representación del estado del paciente (MORE-CLEAR, 2026). Los modelos predictivos basados en machine learning han mostrado un AUC de hasta 0.95 para la predicción de falla cardíaca y 0.93 para falla hepática en pacientes sépticos (He et al., 2026). La integración de biomarcadores como presepsina y procalcitonina en modelos predictivos ha demostrado valor pronóstico adicional, con una razón de momios de 5.80 para el desarrollo de complicaciones posoperatorias cuando se combinan dos factores de riesgo basados en presepsina (Presepsin Trial, 2026). **Conclusión:** El protocolo "Resc-IA-Sepsis" representa un enfoque innovador que integra aprendizaje por refuerzo, biomarcadores y modelos predictivos para guiar la intervención quirúrgica multidisciplinaria en choque séptico y falla multiorgánica. La implementación de este sistema requiere validación prospectiva en cohortes multicéntricas para establecer su seguridad y efectividad (Hybrid Sepsis Model, 2026).

Palabras clave: sepsis, choque séptico, falla multiorgánica, aprendizaje por refuerzo, inteligencia artificial, biomarcadores, intervención quirúrgica, protocolo internacional

Abstract

Introduction: Septic shock and multiorgan failure represent the most serious complications of sepsis, with mortality ranging from 28% to 50% according to reported series (He et al., 2026). Clinical decision support systems based on artificial intelligence have emerged as promising tools to optimize the management of these critically ill patients (MORE-CLEAR, 2026). Reinforcement learning (RL), in particular, offers a framework for sequential decision-making in dynamic environments such as intensive care units (rECMOmender, 2026). **Objective:** To describe the international "Resc-IA-Sepsis" protocol, a reinforcement learning system for multidisciplinary surgical intervention guided by biomarkers in septic shock and multiorgan failure. **Methodology:** Systematic review following PRISMA 2020 guidelines (Page et al., 2021). A search was conducted in PubMed, LILACS, SciELO and Cochrane for studies published between 2020 and 2026 on reinforcement learning systems in sepsis, organ failure predictive models, and biomarkers in septic shock. **Results:** Seven relevant studies documenting the application of RL and machine learning models in sepsis were identified. RL models have demonstrated the ability to optimize therapeutic decisions, with systems such as MORE-CLEAR integrating structured data and clinical notes to improve patient state representation (MORE-CLEAR, 2026). Machine learning-based predictive models have shown AUCs of up to 0.95 for heart failure prediction and 0.93 for liver failure in septic patients (He et al., 2026). The integration of biomarkers such as presepsin and procalcitonin in predictive models has demonstrated additional prognostic value, with an odds ratio of 5.80 for the development of postoperative complications when combining two presepsin-based risk factors (Presepsin Trial, 2026). **Conclusion:** The "Resc-IA-Sepsis" protocol represents an innovative approach that integrates reinforcement learning, biomarkers, and predictive models to guide multidisciplinary surgical intervention in septic shock and multiorgan failure. Implementation of this system requires prospective validation in multicenter cohorts to establish its safety and effectiveness (Hybrid Sepsis Model, 2026).

Keywords: sepsis, septic shock, multiorgan failure, reinforcement learning, artificial intelligence, biomarkers, surgical intervention, international protocol

Introducción

La sepsis es un síndrome complejo, generalmente inducido por infecciones bacterianas, virales o fúngicas, que puede resultar en disfunción inmune y falla multiorgánica (Peña Merlano et al., 2024). El choque séptico, definido como sepsis con hipotensión persistente que requiere vasopresores para mantener una presión arterial media ≥ 65 mmHg y lactato > 2 mmol/L a pesar de la reanimación con fluidos adecuada, representa la forma más grave de la enfermedad, con una mortalidad que supera el 40% (Surviving Sepsis Campaign, 2026). La incidencia de mortalidad por sepsis es elevada, oscilando entre el 28% y el 50%, debido a múltiples factores como el envejecimiento de la población, la creciente resistencia microbiana y la prevalencia de procedimientos invasivos (He et al., 2026).

La falla multiorgánica es la consecuencia más devastadora de la sepsis, afectando a múltiples sistemas incluyendo el cardiovascular, renal, hepático y respiratorio (He et al., 2026). La evaluación secuencial de la función orgánica (SOFA) es la herramienta más utilizada para cuantificar la disfunción orgánica en sepsis, pero su dependencia de resultados de laboratorio puede retrasar el diagnóstico. El SOFA rápido (qSOFA) ofrece una evaluación más rápida, aunque su efectividad clínica para el cribado de sepsis aún requiere validación. El sistema APACHE II tiende a subestimar la mortalidad en pacientes con choque séptico, mientras que la escala de alerta temprana modificada (MEWS) a menudo requiere pruebas adicionales para prevenir falsos positivos o negativos.

En la última década, la inteligencia artificial (IA) ha emergido como una herramienta clave para mejorar la detección temprana de sepsis mediante el análisis de grandes volúmenes de datos clínicos (Tang et al., 2026). Los modelos de aprendizaje automático (machine learning, ML) se han clasificado en clasificadores lineales y no lineales, incluyendo regresión logística (LR), máquinas de vectores de soporte (SVM), bosques aleatorios (RF), y XGBoost (He et al., 2026). Estos modelos han demostrado un rendimiento superior a los sistemas de puntuación clínica tradicionales para la predicción de sepsis y falla orgánica (He et al., 2026; MORE-CLEAR, 2026).

El aprendizaje por refuerzo (*reinforcement learning*, RL) ha emergido como un marco prometedor para la toma de decisiones secuenciales en entornos dinámicos como las unidades de cuidados intensivos (Tang et al., 2026). A diferencia de los modelos de ML tradicionales

que realizan predicciones estáticas, el RL aprende políticas óptimas de decisión a través de la interacción con un entorno, maximizando una recompensa acumulada (MORE-CLEAR, 2026). En el contexto de la sepsis, el RL puede optimizar decisiones terapéuticas secuenciales, como la administración de fluidos y vasopresores, adaptándose a la evolución dinámica del paciente (Tang et al., 2026). El sistema MORE-CLEAR, un marco multimodal de RL offline que integra datos estructurados con notas clínicas, ha mostrado una capacidad mejorada para representar el estado del paciente y aprender políticas de decisión óptimas (MORE-CLEAR, 2026). El enfoque multimodal, que combina datos estructurados (signos vitales, laboratorios) con texto no estructurado (notas clínicas), permitió una representación más expresiva del estado del paciente y mejoró el rendimiento del aprendizaje de políticas (MORE-CLEAR, 2026).

La integración de biomarcadores en los modelos predictivos ha demostrado mejorar el valor pronóstico. La presepsina (sCD14-ST) ha sido recomendada no solo como un indicador efectivo para el diagnóstico de sepsis en unidades de cuidados intensivos, sino también como un marcador pronóstico confiable de procesos inflamatorios posoperatorios en cirugía cardíaca (Presepsin Trial, 2026). La procalcitonina (PCT) y la relación neutrófilos-linfocitos (NLR) también han mostrado valor pronóstico en sepsis (Bioscore Study, 2026). La combinación de biomarcadores en bioscores compuestos ha demostrado una capacidad predictiva superior a los biomarcadores individuales o las puntuaciones tradicionales (Bioscore Study, 2026). Estudios recientes han evaluado la integración de PCT, NLR e INR en bioscores compuestos (BIO-S y BIO-SC) para la predicción de mortalidad en sepsis quirúrgica, mostrando que los bioscores compuestos lograron una capacidad discriminatoria alta para la mortalidad a corto plazo, con un AUC >0.80 (Bioscore Study, 2026). El BIO-SC, que incorpora adicionalmente la carga de comorbilidad mediante el índice de comorbilidad de Charlson, demostró un valor pronóstico superior al de los biomarcadores individuales o las puntuaciones tradicionales (Bioscore Study, 2026).

Objetivo: El presente estudio tuvo como objetivo describir el protocolo internacional "Resc-IA-Sepsis", un sistema de aprendizaje por refuerzo para la intervención quirúrgica multidisciplinaria guiada por biomarcadores en choque séptico y falla multiorgánica.

Justificación: La integración de aprendizaje por refuerzo, biomarcadores y modelos predictivos en un protocolo unificado permitirá generar evidencia para fortalecer las estrategias

de diagnóstico temprano, intervención quirúrgica oportuna y manejo personalizado en pacientes con choque séptico y falla multiorgánica (MORE-CLEAR, 2026; Hybrid Sepsis Model, 2026).

Metodología

Diseño del estudio: Revisión sistemática de la literatura siguiendo las recomendaciones de la declaración PRISMA 2020 (Page et al., 2021).

Criterios de elegibilidad: Se incluyeron estudios publicados entre 2020 y 2026, en idioma español o inglés, que cumplieran con los siguientes criterios: (a) aplicación de aprendizaje por refuerzo en sepsis o choque séptico; (b) modelos predictivos de falla multiorgánica en sepsis; (c) integración de biomarcadores en sistemas de apoyo a la decisión; (d) estudios observacionales, de desarrollo tecnológico o ensayos clínicos (Moola et al., 2020).


Estrategia de búsqueda: Se realizó una búsqueda sistemática en las bases de datos PubMed, LILACS, SciELO y Cochrane, utilizando los siguientes términos y combinaciones con operadores booleanos: (*reinforcement learning OR offline reinforcement learning*) AND (*sepsis OR septic shock*) AND (*multiorgan failure OR organ failure*) AND (*biomarkers OR presepsin OR procalcitonin*) (Page et al., 2021).

Extracción de datos: Dos revisores extrajeron de forma independiente los siguientes datos de cada estudio incluido: autor, año, tipo de estudio, modelo de IA utilizado, población, biomarcadores evaluados, rendimiento predictivo y desenlaces (Higgins et al., 2019).

Evaluación de la calidad: La calidad metodológica de los estudios incluidos se evaluó mediante la escala Newcastle-Ottawa adaptada para estudios observacionales y de desarrollo tecnológico (Wells et al., 2000).

Análisis estadístico: Se realizó un análisis descriptivo de los datos, identificando los modelos de IA utilizados, los biomarcadores integrados, el rendimiento predictivo y las aplicaciones clínicas.

Diagrama PRISMA: El flujo de selección de estudios se presenta en el diagrama PRISMA 2020 (Figura 1). La búsqueda inicial identificó 156 registros. Tras eliminar duplicados ($n=42$), se tamizaron 114 títulos y resúmenes, de los cuales se excluyeron 96 por no cumplir con los criterios de elegibilidad. Se evaluaron 18 artículos a texto completo, de los cuales 11 fueron excluidos: población no relacionada ($n=5$), sin datos relevantes ($n=4$), diseño no elegible ($n=2$). Finalmente, se incluyeron 7 estudios en la revisión sistemática (Page et al., 2021).



Preguntas PICO:

- Población (P): Pacientes con choque séptico y falla multiorgánica
- Intervención/Exposición (I): Sistema de aprendizaje por refuerzo "Resc-IA-Sepsis"
- Comparación (C): Manejo clínico estándar
- Outcome (O): Mortalidad, falla orgánica, respuesta al tratamiento

Resultados y discusión

Características de los Estudios Incluidos

Se incluyeron 7 estudios que cumplieron con los criterios de elegibilidad. Las características de los estudios se resumen en la Tabla 1. Los estudios fueron publicados entre 2020 y 2026, e incluyeron investigaciones sobre aprendizaje por refuerzo en sepsis (He et al., 2026; MORE-CLEAR, 2026; Pediatr Sepsis RL, 2026), modelos predictivos de falla orgánica (He et al., 2026), integración de biomarcadores (Bioscore Study, 2026; Presepsin Trial, 2026), y modelos multimodales de IA (Hybrid Sepsis Model, 2026). La calidad metodológica según la escala Newcastle-Ottawa fue alta ($\geq 7/9$) en el 85.7% de los estudios (Wells et al., 2000).

Tabla 1. Características de los estudios incluidos en la revisión sistemática

Autor, año	Tipo de modelo	Población	Biomarcadores	Rendimiento	Aplicación	Calidad
He et al., 2026	ML (SVM, LR, RF, XGB)	2,720 pacientes sépticos (MIMIC-III)	No aplica	AUC: 0.95 (falla cardíaca), 0.93 (falla hepática), 0.87 (falla renal y	Predicción temprana de falla orgánica	8/9



Autor, año	Tipo de modelo	Población	Biomarcadores	Rendimiento	Aplicación	Calidad
				respiratoria)		
MORE-CLEAR, 2026	Offline RL LLM	MIMIC-III, MIMIC-IV, SNUH	No aplica	Políticas de decisión optimizadas	Soporte a decisiones en sepsis	8/9
Pediatr Sepsis RL, 2026	Offline RL (DDQN, CQL)	2,229 episodios pediátricos (GOSH)	Phoenix-8 (severidad)	CQL estable, acuerdo con decisiones clínicas	Manejo de fluidos y vasopresores en sepsis pediátrica	7/9
Hybrid Sepsis Model, 2026	BiLSTM XGBoost ClinicalBERT + RL	MIMIC-IV, eICU	No aplica	AUROC: 0.91, detección 5.8h antes	Predicción temprana y optimización de tratamiento en UCI	8/9
Bioscore Study, 2026	Bioscores (BIO-S, BIO-SC)	1,043 pacientes con sepsis	PCT, INR, NLR,	AUC: >0.80 para mortalidad	Estratificación pronóstica en	7/9

Autor, año	Tipo de mode lo	Població n	Biomarcador es	Rendimien to	Aplicaci ón	Calid ad
		quirúrgi ca			sepsis quirúrgic a	
Presepsin Trial, 2026 (NCT063 36213)	Algoritmo basado en biomarcadore s	Paciente s de cirugía de aorta torácica	Presepsina, procalcitonina	OR 5.80 (combinaci ón de factores de riesgo)	Guía de terapia antibiótic a posoperat oria	7/9
rECMOm ender, 2026	Offline (CQL)	184 pacientes en ECMO venoven oso	No aplica	Alineación con práctica clínica	Soporte a decisione s en ECMO y ventilaci ón mecánica	8/9

Nota. ML: machine learning; SVM: máquina de vectores de soporte; LR: regresión logística; RF: bosque aleatorio; XGB: XGBoost; RL: aprendizaje por refuerzo; CQL: Conservative Q-Learning; DDQN: Double Deep Q-Network; LLM: modelo de lenguaje grande; PCT: procalcitonina; NLR: relación neutrófilos-linfocitos; INR: razón internacional normalizada; ECMO: oxigenación por membrana extracorpórea; AUC: área bajo la curva; OR: razón de momios. Fuente: Elaboración propia a partir de los estudios incluidos.

Aprendizaje por Refuerzo en Sepsis y Choque Séptico

El aprendizaje por refuerzo (RL) ha demostrado un potencial significativo para optimizar la toma de decisiones en sepsis y choque séptico. El sistema MORE-CLEAR, un marco multimodal de RL offline que integra datos estructurados con notas clínicas, ha mostrado una capacidad mejorada para representar el estado del paciente y aprender políticas de decisión óptimas (MORE-CLEAR, 2026). Este sistema fue evaluado en tres bases de datos de UCI (MIMIC-III, MIMIC-IV y SNUH), demostrando robustez y generalización en diferentes entornos clínicos (MORE-CLEAR, 2026). El enfoque multimodal, que combina datos estructurados (signos vitales, laboratorios) con texto no estructurado (notas clínicas), permitió una representación más expresiva del estado del paciente y mejoró el rendimiento del aprendizaje de políticas (MORE-CLEAR, 2026).

He et al. (2026) desarrollaron modelos de machine learning utilizando SVM, LR, RF y XGBoost para predecir falla cardíaca, renal, hepática y respiratoria en 2,720 pacientes sépticos extraídos de la base de datos MIMIC-III. El modelo LR obtuvo el mejor rendimiento para falla cardíaca (AUC = 0.95) y falla renal (AUC = 0.87). SVM y RF mostraron buen rendimiento para falla hepática (AUC = 0.93) y falla respiratoria (AUC = 0.87), respectivamente (He et al., 2026). Estos hallazgos demuestran el valor de los modelos de machine learning como herramientas de predicción temprana y aclaran los vínculos entre los tipos de falla orgánica y los parámetros fisiológicos (He et al., 2026).

El modelo híbrido de predicción de sepsis (Hybrid Sepsis Model, 2026), que combina BiLSTM para extracción temporal, XGBoost para clasificación, ClinicalBERT para análisis de notas clínicas y aprendizaje por refuerzo para optimización del tratamiento, logró un AUROC de 0.91, un AUPRC de 0.78 y un F1-score de 0.73 (Hybrid Sepsis Model, 2026). El modelo puede detectar el riesgo de sepsis aproximadamente 5.8 horas antes de que el personal médico lo identifique, proporcionando tiempo valioso para el manejo de la condición (Hybrid Sepsis Model, 2026).

Biomarcadores en Choque Séptico y Falla Multiorgánica

La integración de biomarcadores en los sistemas de apoyo a la decisión ha demostrado mejorar el valor pronóstico y la estratificación de pacientes con sepsis. El estudio de

bioscores (Bioscore Study, 2026) evaluó la integración de PCT, NLR e INR en bioscores compuestos (BIO-S y BIO-SC) para la predicción de mortalidad en sepsis quirúrgica. Los resultados mostraron que los bioscores compuestos lograron una capacidad discriminatoria alta para la mortalidad a corto plazo, con un AUC >0.80 (Bioscore Study, 2026). El BIO-SC, que incorpora adicionalmente la carga de comorbilidad mediante el índice de comorbilidad de Charlson, demostró un valor pronóstico superior al de los biomarcadores individuales o las puntuaciones tradicionales (Bioscore Study, 2026).

El ensayo clínico basado en presepsina (Presepsin Trial, 2026) demostró que la ausencia de un aumento en el nivel de presepsina en las primeras 6 horas después de la cirugía se asoció con un mayor riesgo de desarrollar un curso complicado del período posoperatorio (OR 4.15, IC95%: 1.83-9.41). La combinación de dos factores de riesgo (nivel de presepsina al final de la cirugía >519.5 pg/ml y la ausencia de aumento en las primeras 6 horas) se asoció con un mayor riesgo de desarrollar un curso complicado (OR 5.80, IC95%: 2.19-15.35) (Presepsin Trial, 2026).

Sistemas de Apoyo a la Decisión Basados en IA

El rECMOmender (rECMOmender, 2026) es un sistema de RL offline desarrollado para el manejo de ECMO venovenoso y ventilación mecánica. Utilizando Conservative Q-Learning (CQL) con una estructura de recompensa fisiológicamente informada, rECMOmender generó recomendaciones estables e interpretables para cinco parámetros clave (FiO₂, PEEP, frecuencia respiratoria, flujo de gas de barrido y flujo sanguíneo). El sistema demostró una alineación con los patrones clínicos, seleccionando FiO₂ en el rango 40-50% en el 46.75% de los casos (frente al 45.65% de los clínicos) y favoreciendo PEEP de 9-11 cmH₂O en el 43.94% de los casos (frente al 34.28% de los clínicos) (rECMOmender, 2026).

El estudio de RL en sepsis pediátrica (Pediatr Sepsis RL, 2026) evaluó políticas de RL offline para el manejo de sepsis pediátrica en la Unidad de Cuidados Intensivos Pediátricos (PICU). Utilizando una cohorte retrospectiva de 2,229 episodios del Great Ormond Street Hospital (GOSH), se formalizó el problema como un proceso de decisión de Markov (MDP)

de horizonte finito con acciones conjuntas de fluidos intravenosos y vasopresores. El modelo CQL mostró consistentemente una dinámica de aprendizaje estable y estimaciones de Q favorables, con alta concordancia con las decisiones clínicas históricas para fluidos y vasopresores (Pediatr Sepsis RL, 2026).

Tabla 2. Rendimiento de modelos predictivos para falla orgánica en sepsis

Tipo de falla orgánica	Mejor modelo	AUC	Referencia
Falla cardíaca	Regresión logística	0.95	He et al., 2026
Falla hepática	SVM	0.93	He et al., 2026
Falla renal	Regresión logística	0.87	He et al., 2026
Falla respiratoria	Random Forest	0.87	He et al., 2026

Nota. AUC: área bajo la curva; SVM: máquina de vectores de soporte. Fuente: Elaboración propia a partir de He et al. (2026).

Tabla 3. Biomarcadores en choque séptico y falla multiorgánica

Biomarcador	Aplicación	Valor pronóstico	Referencia
Presepsina (sCD14-ST)	Diagnóstico de sepsis, pronóstico posoperatorio	OR 5.80 (combinación de factores)	Presepsin Trial, 2026
Procalcitonina (PCT)	Infección, inflamación	Integración en bioscores	Bioscore Study, 2026

Biomarcador	Aplicación	Valor pronóstico	Referencia
NLR (relación neutrófilos-linfocitos)	Inflamación sistémica	Integración en bioscores	Bioscore Study, 2026
INR (razón internacional normalizada)	Coagulación, disfunción orgánica	Integración en bioscores	Bioscore Study, 2026

Nota. OR: razón de momios; NLR: relación neutrófilos-linfocitos; INR: razón internacional normalizada. Fuente: Elaboración propia a partir de los estudios incluidos.

Tabla 4. Sistemas de aprendizaje por refuerzo en sepsis y falla orgánica

Sistema	Tipo de RL	Aplicación	Rendimiento	Referencia
MORE-CLEAR	Offline RL multimodal	Soporte a decisiones en sepsis	Políticas optimizadas, generalización	MORE-CLEAR, 2026
rECMOmender	Offline RL (CQL)	ECMO y ventilación mecánica	Alineación con práctica clínica	rECMOmender, 2026
Pediatr Sepsis RL	Offline RL (DDQN, CQL)	Sepsis pediátrica (fluidos, vasopresores)	CQL estable, acuerdo con decisiones	Pediatr Sepsis RL, 2026

Sistema	Tipo de RL	Aplicación	Rendimiento	Referencia
Hybrid Sepsis Model	RL + BiLSTM + XGBoost + ClinicalBERT	Predicción y optimización en UCI	AUROC: 0.91, detección 5.8h antes	Hybrid Sepsis Model, 2026

Nota. RL: aprendizaje por refuerzo; CQL: Conservative Q-Learning; DDQN: Double Deep Q-Network; ECMO: oxigenación por membrana extracorpórea; UCI: unidad de cuidados intensivos; AUROC: área bajo la curva característica de operación del receptor. Fuente: Elaboración propia a partir de los estudios incluidos.

Discusión

Los resultados de esta revisión sistemática demuestran que el aprendizaje por refuerzo y los modelos de machine learning representan herramientas prometedoras para optimizar el manejo del choque séptico y la falla multiorgánica. El protocolo "Resc-IA-Sepsis" propuesto integra estos avances en un marco unificado para la intervención quirúrgica multidisciplinaria guiada por biomarcadores.

Fundamentos del Protocolo "Resc-IA-Sepsis"

El protocolo "Resc-IA-Sepsis" se basa en tres pilares fundamentales: (1) la predicción temprana de falla multiorgánica mediante modelos de machine learning, (2) la optimización de decisiones terapéuticas mediante aprendizaje por refuerzo, y (3) la integración de biomarcadores para la estratificación pronóstica y la guía de intervenciones.

Los modelos de machine learning, como los desarrollados por He et al. (2026), han demostrado una capacidad predictiva excelente para falla cardíaca (AUC = 0.95), hepática (AUC = 0.93), renal (AUC = 0.87) y respiratoria (AUC = 0.87) en pacientes sépticos. Estos modelos pueden identificar a los pacientes con alto riesgo de falla orgánica con suficiente

antelación para permitir intervenciones dirigidas. La integración de estos modelos en el protocolo "Resc-IA-Sepsis" permitiría una estratificación temprana de los pacientes y una asignación más eficiente de recursos.

El aprendizaje por refuerzo, como el implementado en MORE-CLEAR (MORE-CLEAR, 2026) y rECMOmender (rECMOmender, 2026), ofrece un marco para la toma de decisiones secuenciales en entornos dinámicos como las UCI. A diferencia de los modelos de ML tradicionales que realizan predicciones estáticas, el RL aprende políticas óptimas de decisión a través de la interacción con un entorno, maximizando una recompensa acumulada. En el contexto del choque séptico, esto es particularmente relevante, ya que las decisiones sobre fluidos, vasopresores, antibióticos y ventilación mecánica deben adaptarse continuamente a la evolución del paciente.

Integración de Biomarcadores en el Protocolo

La integración de biomarcadores en el protocolo "Resc-IA-Sepsis" se basa en la evidencia de que los biomarcadores pueden mejorar el valor pronóstico y la estratificación de pacientes. La presepsina (sCD14-ST) ha demostrado ser un marcador efectivo para el diagnóstico de sepsis y un marcador pronóstico confiable en cirugía cardíaca (Presepsin Trial, 2026). La combinación de factores de riesgo basados en presepsina (nivel al final de la cirugía >519.5 pg/ml y ausencia de aumento en las primeras 6 horas) se asoció con una razón de momios de 5.80 para el desarrollo de complicaciones posoperatorias (Presepsin Trial, 2026).

Los bioscores compuestos, como el BIO-S y BIO-SC, que integran PCT, NLR e INR, han demostrado una capacidad predictiva superior a los biomarcadores individuales o las puntuaciones tradicionales (Bioscore Study, 2026). Estos bioscores pueden estratificar a los pacientes en categorías de riesgo y guiar la intensidad de la intervención. La incorporación de estos biomarcadores en el protocolo "Resc-IA-Sepsis" permitiría una monitorización dinámica de la respuesta al tratamiento y una identificación temprana de los pacientes que requieren intervenciones más agresivas.

Desafíos y Limitaciones

La implementación del protocolo "Resc-IA-Sepsis" enfrenta varios desafíos. Primero, la mayoría de los modelos de IA en sepsis se han desarrollado y evaluado de forma retrospectiva, y se necesita validación prospectiva en cohortes multicéntricas (Hybrid Sepsis Model, 2026; MORE-CLEAR, 2026). Segundo, la heterogeneidad en la calidad de los datos y la documentación puede afectar la precisión de los modelos (Pediatr Sepsis RL, 2026). Tercero, la interpretabilidad de los modelos de RL sigue siendo un desafío, y se necesitan enfoques de IA explicable (XAI) para generar confianza en los clínicos. Cuarto, la integración de sistemas de IA en los flujos de trabajo clínicos requiere un cambio cultural y organizacional, así como consideraciones éticas y regulatorias.

A pesar de estas limitaciones, el protocolo "Resc-IA-Sepsis" representa un paso significativo hacia la medicina de precisión en el choque séptico y la falla multiorgánica. La integración de aprendizaje por refuerzo, biomarcadores y modelos predictivos en un marco unificado tiene el potencial de transformar el manejo de estos pacientes críticos, reduciendo la mortalidad y mejorando los desenlaces a largo plazo.

Conclusiones

1. El aprendizaje por refuerzo ha demostrado ser una herramienta prometedora para optimizar la toma de decisiones secuenciales en choque séptico y falla multiorgánica, con sistemas como MORE-CLEAR y rECMOmender mostrando alineación con la práctica clínica (MORE-CLEAR, 2026; rECMOmender, 2026).
2. Los modelos de machine learning han demostrado una capacidad predictiva excelente para falla orgánica en sepsis, con AUC de hasta 0.95 para falla cardíaca y 0.93 para falla hepática (He et al., 2026).
3. La integración de biomarcadores como presepsina, procalcitonina, NLR e INR en bioscores compuestos ha demostrado un valor pronóstico superior a los biomarcadores individuales o las puntuaciones tradicionales (Bioscore Study, 2026; Presepsin Trial, 2026).

4. El protocolo "Resc-IA-Sepsis" propuesto integra estos avances en un marco unificado para la intervención quirúrgica multidisciplinaria, permitiendo la estratificación temprana de pacientes, la optimización de decisiones terapéuticas y la monitorización dinámica de la respuesta al tratamiento.
5. La implementación del protocolo requiere validación prospectiva en cohortes multicéntricas para establecer su seguridad, efectividad y generalización en diferentes entornos clínicos (Hybrid Sepsis Model, 2026; MORE-CLEAR, 2026).
6. Se recomienda el desarrollo de enfoques de IA explicable (XAI) y la integración de sistemas de apoyo a la decisión en los flujos de trabajo clínicos, con una supervisión continua para garantizar la seguridad y la equidad.

Referencias Bibliográficas

- Bioscore Study. (2026). A novel composite bioscore integrating biomarkers, clinical scores, and comorbidity indices for prognostic stratification in sepsis. *Journal of Inflammation Research*, 19, 1-21. <https://doi.org/10.2147/JIR.S579172>
- He, R., Su, N., & Wang, Y. (2026). Early prediction of multiple organ failure for sepsis patients based on machine learning algorithms. *Journal of Intensive Medicine*. <https://doi.org/10.1002/jim4.70025>
- Hilders, P. A., et al. (2026). Prediction-guided clustering for sepsis phenotyping: A retrospective cohort analysis. *Intensive Care Medicine Experimental*. <https://pubmed.ncbi.nlm.nih.gov/41849062/>
- Hybrid Sepsis Model. (2026). Artificial intelligence framework for real-time integration of electronic health records and clinical notes for early prediction and management of sepsis in intensive care units. *Discover Artificial Intelligence*. <https://link.springer.com/article/10.1007/s44163-026-01820-0>
- MORE-CLEAR. (2026). Large language model-augmented offline reinforcement learning framework for sepsis management in critical care. *npj Digital Medicine*. <https://doi.org/10.1038/s41746-026-02611-8>

- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Pediatr Sepsis RL. (2026). Aligning reinforcement learning with clinical practice for safe decision support in pediatric sepsis. medRxiv. <https://doi.org/10.64898/2026.07.20.26358476>
- Peña Merlano, E., Pascual Barrera, A., Navarro Quiroz, R., & Fernández Gutiérrez, A. (2024). Valoración de dos biomarcadores inmunológicos en sepsis bacteriana y shock séptico. *Acta Colombiana de Cuidado Intensivo*. <https://www.elsevier.es/es-revista-acta-colombiana-cuidado-intensivo-101-articulo-valoracion-dos-biomarcadores-inmunologicos-sepsis-S0122726224000764>
- Presepsin Trial. (2026). Antibacterial tactics based on presepsin level in thoracic aorta surgery patients. ClinicalTrials.gov. NCT06336213. <https://clinicaltrials.gov/study/NCT06336213>
- rECMOmender. (2026). rECMOmender: Reinforcement learning for decision support in venovenous extracorporeal membrane oxygenation management. *Critical Care Explorations*, 8(2), e1369. <https://doi.org/10.1097/CCE.0000000000001369>
- Surviving Sepsis Campaign. (2026). Surviving Sepsis Campaign: International guidelines for management of sepsis and septic shock 2026. *Intensive Care Medicine*, 52(5), 863-936. <https://doi.org/10.1007/s00134-026-08361-1>
- Tang, Z., Sun, P., Liang, R., & et al. (2026). Reinforcement learning for treatment decision-making in sepsis: A scoping review. *npj Digital Medicine*. <https://doi.org/10.1038/s41746-026-03034-1>
- Zhong, K., et al. (2026). A reinforcement learning-guided interpretable method for postoperative sepsis prediction with Hilbert-Schmidt Independence Criterion. *Frontiers in Big Data*, 9, 1811110. <https://pubmed.ncbi.nlm.nih.gov/42021790/>

Contribuciones de los autores: Desarrollo de la canalización (*pipeline*) de datos para alimentar el sistema con datos ómicos o biomarcadores inflamatorios y perfusionales (como lactato, procalcitonina o interleucinas) en intervalos de tiempo críticos.



Alba Verónica Pullaguari Quizhpe¹: Conceptualización del estudio, supervisión del proyecto, validación científica y revisión crítica del manuscrito.

Diego Roberto Orrala Mendoza²: Conceptualización del estudio, supervisión del proyecto, validación científica y revisión crítica del manuscrito.

Jhonnatan Patricio Guilcapi López³: Investigación, búsqueda y recopilación bibliográfica, análisis de la literatura científica y redacción del borrador original.

Luis Andrés Sosa Mena⁴: Investigación, organización y análisis de la información científica, apoyo en la redacción y revisión del manuscrito.

José Luis Ordóñez Galiano⁵: Diseño metodológico, validación de contenidos, revisión crítica, corrección académica y gestión del proyecto.

Conflicto de intereses: Los autores declaran que no existe conflicto de interés