

# Estudio exploratorio sobre el uso de técnicas de Machine Learning para la estimación de demanda de servicios de salud

Gabriel Alfonso Rojas Niampira<sup>1</sup>, Laura Yeraldin Escobar Rodríguez<sup>2,\*</sup>

<sup>1</sup>Escuela de estudios industriales y empresariales, Universidad industrial de Santander, Colombia

<sup>2</sup>Escuela de estudios industriales y empresariales, Universidad industrial de Santander, Colombia

**Resumen** Este estudio exploratorio analiza más de 40 artículos relacionados con el uso de técnicas de machine learning para la estimación de demanda de servicios de salud, con el fin de clasificar los algoritmos o modelos aplicados en las diferentes áreas del sector. La clasificación realizada busca facilitar a los investigadores un mejor enfoque en sus trabajos, al identificar las técnicas más empleadas y las áreas específicas en las que han demostrado mayor efectividad. En la revisión bibliográfica y clasificación permiten concluir que el aprendizaje supervisado, especialmente mediante modelos como LSTM, Random Forest, XGBoost y enfoques híbridos como BILSTM-GASVR, ha demostrado un desempeño sólido en la estimación de la demanda de servicios de salud, aplicándose en ámbitos diversos como bancos de sangre, cuidados intensivos, programas de vacunación y gestión hospitalaria, evaluados principalmente con métricas como RMSE, MAE y precisión. En este sentido, el estudio se plantea como una herramienta de apoyo para futuras investigaciones, ofreciendo una visión clara y organizada sobre el uso de estas técnicas en el ámbito de la salud.

**Palabras clave** Pronostico, Demanda, Aprendizaje automático, Modelos predictivos, Servicios, Salud

**AMS 2010 subject classifications**

**DOI:**

## 1. Introducción

Durante los últimos años, la salud ha tenido una transformación exponencial; la gestión eficiente de los recursos y la demanda de los servicios de salud son muy importantes para garantizar una atención oportuna y de alta calidad al usuario. Este estudio exploratorio aborda el uso de técnicas de Machine Learning para la estimación de la demanda en servicios de salud, ya que presenta una visión innovadora con respecto a los métodos tradicionales, ya que a menudo estos métodos tradicionales no logran analizar todas las variables y la gran complejidad de los datos. Investigaciones previas han demostrado el potencial de estas técnicas en la predicción y optimización de recursos, destacando su aplicación en áreas como la planificación hospitalaria, la gestión de emergencias, entre otras.

La salud es uno de los derechos fundamentales declarados en Colombia, y disponer de los distintos servicios que la garanticen es tarea crucial del Estado. A pesar de los numerosos esfuerzos en términos de inversión en infraestructura, personal, tecnología, entre otros, que se han realizado en los últimos años, existen aún municipios que no cuentan con hospitales, lo que a su vez representa población que no tiene acceso a servicios de salud. (Constitución Política de Colombia, 1991, art. 48 y 49) [23, 27, 16].

Colombia y el mundo tienen problemas en los sistemas de salud, ya que cuentan con recursos limitados y una población por atender variable, por lo que existe la necesidad de contar con una estimación precisa de la demanda para una adecuada planificación de recursos y mejora en la calidad de la atención [5]. En ese sentido, el uso de

\*Correspondencia a: Laura Escobar (Email: layesrod@correo.uis.edu.co). Escuela de estudios industriales y empresariales, Universidad Industrial de Santander. Bucaramanga, Santander, Colombia (680002).

técnicas de Machine Learning ofrece un enfoque prometedor para abordar este desafío, ya que permite el análisis de grandes volúmenes de datos y la identificación de patrones complejos que pueden influir en la demanda [15].

El uso de técnicas de machine learning para la estimación de demanda de servicios de salud mejora la planificación de recursos, optimiza la calidad de atención, identifica patrones epidemiológicos, personaliza la atención médica y acelera la toma de decisiones basada en evidencia [28]. Estos beneficios potenciales justifican la realización de un estudio exploratorio que aproveche las técnicas de machine learning y los datos disponibles para mejorar la gestión y predicción de servicios de salud.

Un reto adicional asociado al uso de técnicas Machine Learning supone la disponibilidad de datos numerosos, incompletos y heterogéneos, lo que dificulta su análisis y utilización. La falta de una metodología robusta y precisa para la estimación de la demanda puede resultar en una asignación inadecuada de recursos, tanto en términos de personal médico como de equipos y medicamentos. En ese sentido, el presente proyecto propone desarrollar una base de conocimiento que pueda servir como punto de partida a los futuros investigadores que deseen aportar desde la academia a problemas del contexto regional, nacional e internacional.

Ahora bien, de forma preliminar se realizó una búsqueda de la literatura científica disponible asociada al tema y se encuentra que entre los años 2014 y 2024 se registraron 323 documentos en la base de datos Scopus. Lo anterior da cuenta de que es un tema vigente y que se ha desarrollado en distintas partes del mundo, por lo que este estudio exploratorio aportaría a la consolidación y estructuración de dicha información. Ya en un segundo filtro más detallado se encontraron 69 documentos que serían de gran aporte a la investigación. Cabe resaltar que se espera que futuros estudiantes tanto de pregrado como de posgrado puedan tomar este estudio como base para el desarrollo de trabajos asociados a la mejora, desde distintas aristas, del sector salud en Colombia.

El objetivo de este proyecto es analizar las diferentes técnicas de Machine Learning aplicadas para la planificación de recursos y la toma de decisiones en salud pública y privada, permitiendo anticipar la demanda y ajustar los servicios a las necesidades reales de la población. Este estudio exploratorio radica en la necesidad de herramientas predictivas más precisas y dinámicas que las actualmente empleadas, ofreciendo así un enfoque que podría transformar la gestión sanitaria, y adicionalmente la necesidad de una caracterización más precisa del uso de las técnicas de machine learning en las diferentes áreas de la salud.

Por los argumentos expuestos anteriormente, se destaca la importancia crítica de la demanda de servicios de salud y cómo las técnicas de machine learning ofrecen una perspectiva innovadora para mejorar su estimación. Al mismo tiempo, se enfatiza la necesidad de superar los desafíos actuales y explorar nuevas oportunidades para integrar estas técnicas en la práctica clínica de manera efectiva y ética.

## 2. Metodología

Para la construcción de este artículo se ejecutaron las fases mostradas en la **Figura 1** con el fin de cumplir con los objetivos establecidos para la ejecución total del estudio. La investigación se desarrolló en cinco fases. En la primera, se realizó una búsqueda preliminar en bases de datos como SCOPUS y en literatura gris, con el propósito de identificar el estado del arte y recopilar información clave sobre el uso de técnicas de machine learning en la demanda de servicios de salud. La segunda fase se centró en la preparación y definición de la estrategia de búsqueda, seleccionando bases de datos, palabras clave, sinónimos y ecuaciones de búsqueda, lo que permitió obtener un conjunto de artículos representativos y realizar un primer análisis bibliométrico. En la tercera fase, se identificaron las principales técnicas de machine learning aplicadas a la estimación de la demanda de servicios de salud, clasificándolas de acuerdo con sus características y relacionándolas con diferentes áreas de aplicación, como emergencias, servicios ambulatorios, hospitalarios, etc. La cuarta fase estuvo orientada a organizar y redactar el artículo académico bajo el esquema de introducción, metodología, resultados y discusión, cuidando la coherencia, la calidad del contenido y la adaptación a los criterios de una revista científica. Finalmente, la quinta fase correspondió a la revisión integral del artículo y la preparación de la presentación, asegurando que el documento final cumpliera con todos los requisitos establecidos para su difusión académica.

El objetivo de la investigación es realizar un estudio exploratorio. Para ello se estructuró una ecuación de búsqueda que contemple palabras clave como: predicción de demanda, servicios de salud y modelos de aprendizaje,




Figura 1. Diagrama de flujo de la metodología.

entre otras, como se muestra en la Tabla 1 con sus sinónimos respectivamente. Con este prototipo (Ver **Figura 2**) se encuentra un total de 69 documentos en la base referencial SCOPUS. Se selecciona en primera instancia esta base, considerando que tiene enlazadas diversas casas editoriales como ELSEVIER, SPRINGER, TAYLOR & FRANCIS, entre otras bases de datos médicas como PUDMED y MEDLINE. La búsqueda de documentos se realizó a través de la biblioteca virtual de la Universidad Industrial de Santander, en la sección de herramientas. Se accedió a la base de datos SCOPUS, y para delimitar la búsqueda se aplicaron filtros que restringieron los resultados a un rango de años, comprendido entre 2012 y 2026. Además, en la sección “Search within”, se seleccionó “TITLE-ABS-KEY” con el fin de abarcar todos los campos disponibles en dicho ítem, se filtró el tipo de documento por “ARTICLE” y “CONFERENCE PAPER” y además se filtró por idioma “ENGLISH” y “SPANISH”. Finalmente, se introdujo la ecuación de búsqueda en el ítem “Search documents” y se ejecutó la consulta. En la Figura 2, se presenta la ecuación de búsqueda utilizada para la inmersión inicial en el tema de investigación.

Tabla 1. *Tesaurus de términos principales*

Término en español	Términos principales en inglés	Sinónimos/Términos equivalentes en inglés
<b>Pronósticos de demanda</b>	Demand prediction	Demand forecasting, demand estimation, demand projection
<b>Servicios de salud</b>	Healthcare services	Medical care, health services, healthcare provision, health industry, healthcare sector
<b>Machine Learning y modelos predictivos</b>	Machine learning models	Machine learning algorithms, predictive models, forecasting models

*Nota.* Adaptado por el autor.

```

TITLE-ABS-KEY ( ( ( "demand prediction" OR "demand forecast*" OR "demand estimation" OR "demand projection" ) AND ( "health" OR "healthcare" OR "health care" OR "medical care" OR "health service*" OR "health industry" OR "health sector" ) AND ( "machine learning" ) ) ) AND PUBYEAR > 2012 AND PUBYEAR < 2026 AND ( LIMIT-TO ( DOCTYPE , "ar" ) OR LIMIT-TO ( DOCTYPE , "cp" ) ) AND ( LIMIT-TO ( LANGUAGE , "English" ) OR LIMIT-TO ( LANGUAGE , "Spanish" ) )
  
```

Figura 2. Ecuación de búsqueda .

A partir de estos documentos filtrados de las bases de datos, se realizó una revisión exhaustiva de cada uno de los documentos y un filtrado más detallado eligiendo los más relevantes para el estudio teniendo en cuenta los siguientes aspectos: relevancia académica, publicaciones más recientes, aplicabilidad, calidad académica, contribución académica, diversidad de enfoques y usos en el campo de la salud. Con este filtrado final se pudieron

obtener mas de 40 documentos relevantes para el estudio de los cuales se creó una bitácora en donde se extrajeron los siguientes ítems más importantes de cada uno de los documentos: área de la salud, tipo de servicio de salud analizado, propósito del estudio, técnica de machine learning, tipo de algoritmos o modelos utilizados, resultados encontrados, indicadores utilizados para medir el desempeño de los algoritmos, futuros trabajos y definición de demanda (unidades). Esto con el fin de hacer un análisis posterior y poder clasificar los distintos tipos de machine learning usados para la demanda de servicios de salud. (ver Anexo 1)

### 3. Resultados

La bibliografía condensada en la bitácora (ver Anexo 1) se observó un crecimiento exponencial en la producción de documentos científicos en los años durante y después de la pandemia del COVID-19, haciéndose evidente la necesidad de la investigación en el uso de técnicas de machine learning en el campo de la salud, específicamente en la estimación demanda de servicios de salud. En la Figura 3 se presenta la evolución de dichas publicaciones entre 2016 y 2025, considerando que este último año aún está en curso y, por tanto, faltan investigaciones por incorporarse, dado que el presente estudio se desarrolló en este periodo y considerando que se sigue esta tendencia en posteriores años, estas investigaciones pueden incrementar. Lo anterior refleja no solo la relevancia de este trabajo, sino también el potencial que ofrece como base para futuras investigaciones en el campo.




Figura 3. Documentos publicados por año.

Considerando los ítems consignados en la bitácora (ver Anexo 1), se realizaron diversos análisis. Se identificó que el aprendizaje supervisado fue utilizado en el 95 % de los documentos revisados para la estimación de la demanda de servicios de salud, mientras que el aprendizaje no supervisado representó un 3 % y el aprendizaje híbrido (combinación de supervisado y no supervisado) correspondió al 2 %, como se muestra en la figura 4. Este análisis inicial permite evidenciar que el aprendizaje por refuerzo no ha tenido un uso significativo en los estudios consultados.

En la figura 5, se ilustran los algoritmos más usados. El tamaño de cada término indica su frecuencia, destacando los siguientes: regresión lineal, bosque aleatorio (random forest), XGBoost (Extreme Gradient Boosting), LSTM (Long Short-Term Memory), entre otros. Esto con el fin de ver un panorama general de estos y posteriormente hacer un análisis más profundo y la clasificación que se busca con este estudio.

Se clasificaron los distintos tipos de machine learning y tipos de algoritmos en diferentes áreas de la salud, como se puede observar en la Tabla 2, para facilitar la identificación de los algoritmos usados para la estimación de la demanda de diferentes servicios de salud. Esto facilitará futuras investigaciones que quieran profundizar en el campo de la salud.




Figura 4. Diagrama pastel de tipos de machine learning usados en la estimación de demanda de servicios de salud.



Figura 5. Nube de palabras de algoritmos de machine learning.

### 3.1. Cuidados intensivos (UCI)

En el área de cuidados intensivos (UCI) se destacan los siguientes trabajos de investigación. En el estudio realizado por [40] utilizó algoritmos como BILSTM, GASVR, LSTM, entre otros, con el objetivo estimar la demanda de recursos de salud en la UCI para mejorar la toma de decisiones y la eficiencia en el tratamiento de pacientes críticos, se encontró que el algoritmo híbrido BILSTM-GASVR obtuvo resultados más cercanos a valores reales en comparación con los otros modelos y mostró una buena eficacia.

[34] usó algoritmos como: Sistema de Inferencia Neuro-Difusa Adaptativo (ANFIS), Memoria de Largo Corto Plazo (LSTM), Regresión de Soporte Vectorial (SVR) y Modelo de Árbol de Decisión, con el propósito de predecir la demanda de ingresos hospitalarios por COVID-19 para facilitar la planificación de recursos sanitarios. El modelo ANFIS tuvo un mejor rendimiento predictivo en comparación con los otros modelos.

[35] querían predecir el deterioro de la salud de los pacientes relacionado al COVID-19 para anticipar la necesidad de admisión a UCI en las próximas 24 a 96 horas, facilitando así la gestión de recursos hospitalarios, se utilizó el algoritmo XGBoost que obtuvo buenos resultados en términos de eficacia para la predicción de admisiones a UCI, destacando la tasa respiratoria máxima como la característica más importante.

Tabla 2. *Tipos de machine learning y algoritmos usados en distintas áreas de la salud*

Área de la salud	Aprendizaje supervisado	Aprendizaje no supervisado
Cuidados intensivos (UCI)	BILSTM, GASVR, ANFIS (Sistema de Inferencia Neuro-Difusa Adaptativo), LSTM (Memoria de Largo Corto Plazo), SVR (Regresión de Soporte Vectorial), Modelo de Árbol de Decisión, XGBoost, Redes Neuronales Artificiales (ANN), Regresión por Vector de Soporte (SVR), Redes neuronales autorregresivas, Redes neuronales artificiales (ANN)	
Servicios médicos (Atención a ancianos, pacientes crónicos, etc.)	Random Forest (RF), Gradient Boosting Decision Tree (GBDT), LightGBM, Regresión Logística (LR), Análisis Discriminante Cuadrático (QDA), XGBoost (XGB), Deep Multi-Task Learning (DMTL), Máquinas de soporte vectorial (SVM), LightGBM con SHAP, Logistic Regression, Logistic Regression con regularización LASSO	stacked autoencoders (SAE)
Distribución y suministro de sangre	LSTM (Long Short-Term Memory), Random Forest, XGBoost, Support Vector Machine (SVM), K-Nearest Neighbors (KNN), Red Neuronal Convolutacional (1D CNN), GRU, Redes Neuronales Artificiales (ANN), Regresión Lineal (LR), SVR, Series temporales (AUTOREG, ARMA, ARIMA, STL), XGBoost, Prophet, Regresión Lasso, Bosque Aleatorio, Redes LSTM	K-means para la agrupación (clustering) de datos
Vacunación	LSTM, Algoritmo Mejorado de Honey Badger (IHBA), Híbrido LSTM-IHBA, ARIMA, SARIMA, Regresión Lineal, XGBoost, GRU, BILSTM, Random Forest Regressor (RFR)	
Farmacéutico (Medicamentos)	GRU, optimización MILP, Algoritmo GOA, LSTM, ARIMA, Modelos de pronóstico proyectivo (AR, MA, ARMA, ARIMA, LSTM), Modelos de pronóstico causal (VAR, RNN, GRU, LSTM, VARMAX), Modelos estocásticos (Base Stock Model, Continuous Review Model), Random Forest, LGBM, Gradient Boosting basado en histogramas y XGBoost, LST, ARIMA, ETS, RNN	
Hospitalización	XGBoost, Regresión lineal/logística, k-vecinos, árboles de decisión, bosques aleatorios, LSTM, ANFIS, SVR, Modelo de Árbol de Decisión	
Emergencias	Redes Neuronales Artificiales (ANN), ARIMA, SMA, NAR, Wavelet-NAR, Rolling window, Regresión (lineal, Poisson, binomial negativa), Árboles de decisión, Random Forest, SVR (Linear, RBF, Sigmoid, Poly), Bagging regressor, Gradient boosting regressor, XGBoost, Ensemble regressor, RIST, Cox-ANN, BiGCN, Regional Moving Average, MLP, RBFN, LightGBM, DNN, GA, DNN-I-GA, SVM (RBF, lineal), RF, R-LASSO, GLM, ARIMA estacional, ARIMAX, Regresión Logística, Árbol CRT	
Epidemiología	ARIMA, SARIMA, Regresión Lineal, XGBoost, Modelo de Campo Neural Bayesiano (BAYESNF)	

*Nota.* Elaboración propia a partir de la revisión de literatura.

[7] usó algoritmos de Redes Neuronales Artificiales (ANN) y Regresión por Vector de Soporte (SVR) para mejorar la eficiencia energética en el sistema de refrigeración de un hospital y resolver problemas comunes en su

funcionamiento, la combinación de estos algoritmos mejoró la eficiencia energética y redujo significativamente el encendido y apagado de los chillers( enfriadora de agua) (82.5 %) y se estimó un ahorro energético entre 7 % y 10 % por año.

[10] usó Redes neuronales autorregresivas (ARNN),Redes neuronales artificiales tradicionales (ANN) y un modelo compartimental epidemiológico que simula como se propaga la enfermedad, con el objetivo de proporcionar herramientas y pronósticos para ayudar a las autoridades a estimar la demanda de camas en UCI durante el crecimiento exponencial de casos de COVID-19, al finalizar el estudio se encontró que los modelos utilizados fueron muy precisos, logrando tasas de error promedio de 4 % para la primera semana y 9 % para la segunda semana.

### 3.2. *Servicios médicos*

[38] utilizaron Random Forest (RF), Gradient Boosting Decision Tree (GBDT) y Light Gradient Boosting Machine (LightGBM) con el objetivo de construir un modelo predictivo para la demanda de servicios médicos y de atención diaria de los ancianos y explorar los factores que influyen en esta demanda. El modelo LightGBM tuvo el mejor rendimiento en la predicción de la demanda de servicios, mostrando buenos resultados en términos de métricas de rendimiento.

[6] empleó algoritmos de Regresión Logística (LR), Análisis Discriminante Cuadrático (QDA) y XGBoost (XGB) con el fin de predecir la demanda de servicios de Atención a Largo Plazo (LTC) para pacientes con cáncer y identificar los factores cruciales que influyen en dicha demanda, los modelos lograron buenos resultados, con AUROC que varió de 0.707 a 0.837, lo que sugiere un rendimiento efectivo.

[26] aplicó Multi-Task Learning (MTL) y stacked autoencoders (SAE) ,con el objetivo mejorar la planificación y asignación de recursos en atención médica a través de la predicción precisa de la carga de trabajo requerida de los pacientes y la optimización de recursos disponibles para satisfacer sus necesidades de manera eficiente y minimizando costos, los resultados indicaron que el uso de aprendizaje de múltiples tareas método de aprendizaje Multi-Task Learning (MTL) y la optimización estocástica reducen los costos totales en la atención médica y mejoran la asignación de recursos, mostrando que el modelo propuesto es más efectivo que métodos convencionales.

[41] aplicó los algoritmos LightGBM junto con la técnica de interpretación SHAP para la predicción de la demanda de servicios asistenciales para ancianos, con el fin de optimizar la carga de trabajo del personal de enfermería. El modelo Fidan (Combinación de LightGBM y el algoritmo SHAP) tiene una precisión del 86.61 % en la predicción de la demanda de servicios.

[14] aplicaron Logistic Regression, Logistic Regression con regularización LASSO, Support Vector Machine (SVM), Random Forest, y Extreme Gradient Boosting (XGBoost), para predecir la demanda de servicios médicos en HCBS para adultos mayores, se encontraron buenos resultados, los modelos Random Forest y XGBoost produjeron resultados robustos con más del 80 % de especificidad, y mostraron ser efectivos en la validación del conjunto de datos.

### 3.3. *Distribución y suministro de Sangre*

[39] tenían como objetivo en su estudio mejorar la precisión y fiabilidad de las predicciones de demanda de sangre utilizando los modelos individuales LSTM (Long Short-Term Memory) y XGBoost,combinando estos modelos se tiene un modelo híbrido LSTM-XGBoost que superó a los modelos individuales, logrando mayor precisión en la previsión de la demanda de sangre.

[30] aplicó el algoritmo de aprendizaje no supervisado K-means para realizar la agrupación (clustering) de los datos con el objetivo de identificar subgrupos de pacientes con alta utilización de inmunoglobulina utilizando datos de registros de salud electrónicos (EHR) para facilitar la planificación de recursos en situaciones de alta demanda, se identificaron seis grupos de pacientes, cada uno con características y patrones de uso diferentes, evidenciando un uso significativo de inmunoglobulina en ciertas agrupaciones.

[29] en su estudio evalúan algoritmos como: Random Forest, XGBoost, Support Vector Machine (SVM), K-Nearest Neighbors (KNN),Red Neuronal Convolutiva (1D CNN) y Unidades Recurrentes Gated (GRU) ,con el objetivo de mejorar la gestión de donaciones de sangre para predecir donantes potenciales y optimizar la asignación

de recursos . Los modelos fueron eficaces, especialmente Random Forest y el XGBoost, que mostraron buenos resultados en la predicción de donantes y demanda de sangre.

[2] emplearon algoritmos de Redes Neuronales Artificiales (ANN), Regresión Lineal (LR), y Soporte Vectorial de Regresión (SVR), series temporales como AUTOREG, ARMA y ARIMA , el objetivo del estudio es reducir la incertidumbre en la demanda de sangre y mitigar el desperdicio y las escaseces en la cadena de suministro de sangre , los hallazgos del estudio indicaron que los modelos propuestos mejoraron la precisión de las predicciones en comparación con métodos tradicionales; los modelos, especialmente Redes Neuronales Artificiales (ANN) y Soporte Vectorial de Regresión (SVR), mostraron una mejora significativa en la precisión.

[20] en su estudio desarrolló una estrategia eficaz para la gestión de la demanda de recuento de glóbulos rojos (RBC), mediante un modelo de pronóstico de demanda y uso algoritmos como, STL y eXtreme Gradient Boosting (XGBoost), LSTM y regresión lineal. Los resultados mostraron que la estrategia de pedido integrada reduce significativamente el nivel de inventario y la frecuencia de pedidos. El modelo híbrido (STL + XGBoost) mostró un error cuadrático medio (RMSE) de 20.3 y un error porcentual absoluto medio (MAPE) de 16.94 % en el conjunto de prueba, aunque el modelo LSTM presentó una precisión similar, el modelo STL + XGBoost fue preferido por su facilidad de uso y capacidad.

[24] utilizó algoritmos ARIMA, Prophet, Regresión Lasso, Bosque Aleatorio y Redes LSTM, con el propósito de presentar un modelo de pronóstico eficiente para la demanda de plaquetas con el fin de mejorar la gestión de la oferta y la demanda en los Servicios de Sangre de Canadá (CBS), los hallazgos indicaron que los modelos multivariados, como la regresión lasso, el bosque aleatorio y LSTM, superan a los métodos univariados, especialmente cuando hay datos limitados disponibles, sin embargo, cuando hay suficiente data, el modelo ARIMA muestra un rendimiento similar.

### 3.4. Vacunación

[1] en su estudio abordó problemas de caducidad de vacunas, el seguimiento y su correcto manejo, a través de un modelo innovador con el fin de predecir la demanda de vacunas y además evaluar la credibilidad de las reseñas. Para el estudio se usaron algoritmos como : LSTM (Memoria a Largo y Corto Plazo) y el Algoritmo Mejorado de Honey Badger (IHBA) y híbrido LSTM-IHBA. Los hallazgos indicaron que el algoritmo propuesto IHBA tenía un RMSE mínimo de 1.3828 para la predicción de demanda y una precisión del 90.6 % en la evaluación de reseñas, mostrando una buena eficacia del modelo.

[33] en su estudio tenía como objetivo predecir los niveles óptimos de stock de vacunas para evitar escasez y exceso, y evaluar la efectividad de diferentes métodos de predicción, usó varios algoritmos entre ellos ARIMA, SARIMA, Regresión Lineal y XGBoost, hallando que ARIMA y XGBoost son particularmente más efectivos en la predicción y se concluyó que los modelos pueden seleccionarse según los requisitos específicos y la aplicación prevista, en vez de seguir un enfoque tradicional.

[13] aplicaron algoritmos como : Recurrent Neural Network (RNN), Gated Recurrent Unit (GRU) y Long Short-Term Memory (LSTM) , Bidirectional Long Short-Term Memory (BiLSTM). El objetivo principal fue desarrollar un sistema inteligente de gestión de la cadena de suministro de vacunas (VSC) que integrara tecnologías como blockchain, IoT y machine learning para solucionar problemas de calidad, previsión de demanda y confianza entre partes interesadas. Los resultados indicaron que el modelo GRU se destacó por su alta precisión, manteniendo el error de predicción anual de la demanda de vacunas en aproximadamente 3

[11] usaron en su estudio el algoritmo Random Forest Regressor (RFR) con el fin de mejorar la predicción de la utilización de vacunas para asegurar que haya suficientes dosis disponibles en cada instalación de salud, previniendo tanto el desabastecimiento como el desperdicio. Los hallazgos indicaron que el nuevo modelo de Random Forest Regressor (RFR) tiene un error de pronóstico mucho menor, casi 18 veces menor que el sistema existente, obteniendo así una mejora en la precisión.

### 3.5. Farmacéutica

[32] aplicaron algoritmos como Red neuronal GRU (Gated Recurrent Unit), optimización MILP y algoritmo de optimización de saltamontes (GOA), con el propósito de mejorar la eficiencia y la precisión en la asignación de recursos durante situaciones críticas, garantizando la disponibilidad de medicamentos. Los resultados del estudio

indicaron que el modelo GRU superó a los demás con una mayor precisión de 0,98. El estudio resalta el potencial de los algoritmos predictivos avanzados y los modelos de optimización para optimizar las operaciones, reducir costos y mejorar la prestación integral de servicios de salud.

[22] en su estudio tiene como objetivo predecir la demanda de medicamentos utilizando modelos ARIMA y LSTM para optimizar el flujo de suministros en el sistema de salud, según sus resultados indicaron que el modelo LSTM mostró un rendimiento superior en comparación con ARIMA en la predicción de la demanda de medicamentos, mostrando mayor precisión y menores tasas de error.

[3] en el estudio usaron diferentes modelos de pronóstico, entre ellos: “Modelos de pronóstico proyectivo: AR (Auto Regression) model, MA (Moving Average) model, ARMA model, ARIMA model, LSTM (Long Short-Term Memory), Modelos de pronóstico causal: VAR (Vector Autoregression) model, RNNs Using Simple RNN and GRU, LSTM (Long Short-Term Memory), VARMAX, Modelos de pronóstico estocástico: Base Stock Model, Continuous Review Model”. El objetivo fue mejorar la gestión del inventario y las proyecciones de demanda de medicamentos para optimizar el acceso y reducir los costos en el sector salud. Los hallazgos indicaron que los modelos desarrollados mejoran la precisión de las predicciones de demanda, evitando desabastecimientos y optimizando los costos de medicamentos.

[19] emplearon algoritmos como Random Forest, LGBM, Gradient Boosting basado en histogramas y XGBoost, con el fin de predecir la demanda de medicamentos esenciales para optimizar la gestión del inventario y mejorar el acceso a estos medicamentos en la provincia de Nghe An en Vietnam. Los resultados indicaron que el modelo Random Forest tiene el mejor rendimiento con un RMSE de 0.95 y altos valores de R cuadrado y R cuadrado ajustado, demostrando su eficacia para la predicción de la demanda.

[8] en su estudio buscó mejorar la precisión de la previsión de la demanda en la industria farmacéutica utilizando un modelo de LSTM optimizado, y comparándolo con otros modelos estadísticos como ARIMA, suavizado exponencial (ETS) y RNN (Redes Neuronales Recursivas). Los resultados mostraron que el modelo LSTM propuesto tiene mejores resultados en comparación con los métodos tradicionales, siendo capaz de capturar mejor las características no lineales de la demanda, logrando un RMSE de 4487,32 y un SMAPE de 0,026, superiores a los obtenidos por los otros modelos.

### 3.6. Hospitalización

[42] compararon algoritmos como Extreme Gradient Boosting (XGBoost), regresión lineal/logística, k-vecinos, árboles de decisión y bosques aleatorios para predecir las admisiones hospitalarias y evaluar el riesgo de enfermedades en función de las condiciones climáticas y la existencia de dos o más enfermedades en los pacientes (comorbilidades). En el estudio, el modelo XGBoost mostró buenos resultados en la predicción de admisiones hospitalarias, con un error promedio de 11.2%. Sin embargo, la influencia de los parámetros climáticos fue menor en comparación con factores como la geografía, el tiempo y las condiciones médicas preexistentes.

[36] en su estudio desarrolló un sistema para pronosticar la demanda de servicios para mejorar la gestión de recursos en cuidados paliativos. Los modelos Long Short-Term Memory (LSTM) demostraron tener un rendimiento asombroso, superando a los métodos convencionales en la predicción de demanda, la precisión de los modelos promedio del 69.75% y un F1-score del 66.8% en predecir los tipos de servicios requeridos por pacientes.

[34] aplicaron varios algoritmos, incluyendo ANFIS (Sistema de Inferencia Neuro-Difusa Adaptativo), LSTM (Memoria de Largo Corto Plazo), SVR (Regresión de Soporte Vectorial) y Modelo de Árbol de Decisión, con el propósito de predecir la demanda de ingresos hospitalarios por COVID-19 para facilitar la planificación de recursos sanitarios. Los hallazgos mostraron que el modelo ANFIS tuvo un mejor rendimiento predictivo en comparación con otros modelos.

### 3.7. Emergencias

En el área de Emergencias, se destacan diversos artículos debido a la importancia crítica de esta especialidad, ya que es un espacio de atención inmediata donde las decisiones rápidas pueden marcar la diferencia entre la vida y la muerte.

[4] aplicó algoritmos, como Redes Neuronales Artificiales (ANN), Autoregressive Integrated Moving Average (ARIMA), Simple Moving Average (SMA), Nonlinear Autoregressive (NAR), y Wavelet Neural Network

(Wavelet-NAR), con el propósito de mejorar la precisión en la predicción de la demanda de servicios de ambulancia de emergencia para optimizar la atención al paciente y la asignación de recursos. Los hallazgos mostraron que el algoritmo Redes Neuronales Artificiales (ANN) tiene una eficacia superior en comparación con otros modelos, obteniendo el mejor desempeño en términos de precisión.

[12] en su estudio los modelos utilizados incluyen un modelo estadístico y un enfoque de machine learning basado en algoritmos de regresión (Rolling window Regression (Linear), Regression (Poisson), Regression (Negative binomial), Decision tree, Random forest, SVR (Linear), SVR (RBF), SVR (Sigmoid), SVR (Poly), Bagging regressor, Gradient boosting regressor, XGBoost regressor y Ensemble regressor). El objetivo era mejorar la gestión del teatro mediante la predicción de la carga diaria de cirugías, buscando optimizar la eficiencia y eficacia en la atención a pacientes. Los resultados muestran que los modelos pueden predecir los conteos diarios de cirugías con una precisión de alrededor del 90 %, aunque la predicción para subgrupos es menos precisa.

[37] en su estudio aplica algoritmos como: Árbol de Supervivencia Imputado Recursivamente (RIST), la regresión de Cox y técnicas de redes neuronales artificiales (Cox-ANN), para mejorar la identificación de pacientes de alto riesgo de readmisión hospitalaria utilizando modelos predictivos basados en análisis de supervivencia, en el estudio se indican que varios modelos de supervivencia pueden capturar de manera efectiva el riesgo de readmisión, siendo especialmente efectivos algunos modelos híbridos Recursively Imputed Survival Tree (RIST), Cox Regression, Hybrid Cox-Artificial Neural Network (Cox-ANN).

[18] aplicaron el Modelo de Red Neuronal Convolutiva de Gráfico Bipartito (BiGCN), con el fin de predecir la demanda de servicios médicos de emergencia (EMS) y comprender la relación entre la oferta y la demanda de EMS, además de contribuir a la gestión de emergencias de salud pública. El modelo de Red Neuronal Convolutiva de Gráfico Bipartito (BiGCN) logró una precisión del 77.3 % - 87.7 %, superando significativamente otros métodos tradicionales y recientes.

[21] usaron algoritmos como Regional Moving Average, Linear Regression, Support Vector Regression (SVR), Multi-layer Perceptron (MLP), Radial Basis Function Network (RBFN) y Light Gradient Boosting Machine (LightGBM). El objetivo fue mejorar la predicción de la demanda de ambulancias para obtener una asignación dinámica de recursos y la planificación del personal en hospitales, asegurando tiempos de espera más cortos para los pacientes en situaciones de emergencia. El modelo LightGBM es el más efectivo para predecir la demanda de ambulancias en comparación con otros métodos, mostrando un buen rendimiento en el análisis.

[17] implementó algoritmos como Redes Neuronales Profundas (DNN) y un algoritmo genético (GA) mejorado para la selección de características, (Redes Neuronales Profundas con selección de características mejorada por algoritmo genético (DNN-I-GA), Máquinas de Vectores de Soporte (SVM) con dos tipos de kernels: kernel Radial (RBF) y kernel lineal, Bosques Aleatorios (Random Forest, RF), Regresión LASSO mejorada (R-LASSO), modelos estadísticos tradicionales como regresión generalizada lineal (GLM), ARIMA estacional y variantes (ARIMAX) y redes neuronales artificiales (ANN). El propósito fue explorar un marco integrado para predecir el flujo de pacientes en A&ED bajo diferentes niveles de triaje. El modelo DNN-I-GA logró la mayor precisión de predicción en comparación con otros modelos utilizados.

[9] aplicó en su estudio los algoritmos de Regresión Logística (LR), Árbol de Clasificación, Regresión (Classification and Regression Tree, CRT) y eXtreme Gradient Boosting (XGBoost), con el objetivo de mejorar la predicción de la demanda de transfusiones de sangre en pacientes traumatizados para asistir a los médicos en la toma de decisiones rápidas y precisas en situaciones críticas; el modelo de XGBoost tuvo la mejor precisión con un AUC de 0.94, superando a la regresión logística y CRT; lo que indica que los modelos usados son eficaces en la predicción de la demanda de transfusiones.

### 3.8. Epidemiología

Por último, en el área de epidemiología se identificó el siguiente estudio más relevante. [31] en su estudio quería proporcionar un modelo que mejore la predicción y el análisis de datos espaciotemporales en aplicaciones de salud pública, como la monitorización de enfermedades y se encontró que el modelo de Campo Neural Bayesiano (BAYESNF) ofrece mejoras significativas en las predicciones en comparación con modelos de referencia existentes, mostrando un buen rendimiento en términos de predicciones puntuales e intervalos de confianza.

Cada uno de estos estudios, como se mencionó anteriormente, se clasificó en la Tabla 2, con el fin de una mejor comprensión y clasificación de cada uno de los algoritmos usados en cada una de las áreas de la salud para la predicción de demanda. En la bibliografía anteriormente mencionada tenemos que la demanda se definió con diferentes unidades, algunas de ellas se definieron como: número de pacientes infectados, número de servicios médicos, número de tipos de servicios, cantidad de sangre, cantidad de vacunas, cantidad de medicamentos, servicios de ambulancias, cantidad de pacientes, número de adultos mayores atendidos, readmisiones no planeadas, cantidad de transfusiones, casos de enfermedades, entre otras.

#### 4. Discusión

En los estudios revisados, los autores coinciden en la necesidad de refinar y adaptar los modelos predictivos a diferentes contextos, explorando la aplicabilidad en escenarios como la gestión de inventarios, bancos de sangre, cuidados intensivos y cadenas de suministro. Se destaca la importancia de integrar fuentes de datos en tiempo real, incluyendo dispositivos IoT, blockchain y datos geoespaciales, para mejorar la capacidad de respuesta de los sistemas. Asimismo, se plantea la exploración de modelos híbridos y enfoques inspirados en el cerebro humano, que permitan optimizar procesos como la programación de citas o la predicción de transferencias de pacientes. Varios trabajos sugieren mejorar la validez externa de los modelos mediante su aplicación a múltiples poblaciones, considerar factores epidemiológicos y demográficos, así como realizar estudios que fortalezcan la implementación en entornos clínicos reales. Finalmente, los autores resaltan la necesidad de incrementar el tamaño y la diversidad de los conjuntos de datos, mejorar la selección de características y continuar el desarrollo de herramientas que faciliten la toma de decisiones en salud de forma más precisa y dinámica.

#### 5. Conclusiones

Los resultados de la revisión bibliográfica y clasificación permiten concluir que el aprendizaje supervisado, especialmente mediante modelos como LSTM, Random Forest, XGBoost y enfoques híbridos como BILSTM-GASVR, ha demostrado un desempeño sólido en la estimación de la demanda de servicios de salud, aplicándose en ámbitos diversos como bancos de sangre, cuidados intensivos, programas de vacunación y gestión hospitalaria, evaluados principalmente con métricas como RMSE, MAE y precisión. En la tabla 3 se clasifican los modelos o algoritmos que tuvieron un mejor rendimiento en cada una de sus áreas específicas de salud, a continuación se mencionan los algoritmos que tuvieron un mejor rendimiento. En el área de cuidados intensivos (UCI): BILSTM-GASVR, ANFIS, XGBoost, Redes Neuronales Artificiales (ANN), Regresión por Vector de Soporte (SVR), Redes neuronales autorregresivas (ARNN), Redes neuronales artificiales tradicionales (ANN). En el área de servicios médicos (atención a ancianos, pacientes crónicos, etc.): LightGBM, Regresión Logística (LR), Análisis Discriminante Cuadrático (QDA) y XGBoost (XGB), Multi-Task Learning (MTL) y stacked autoencoders (SAE), Multi-Task Learning (MTL), Fidan (Combinación de LightGBM y el algoritmo SHAP), Random Forest. En el área de distribución y suministro de Sangre: LSTM-XGBoost, Random Forest y el XGBoost, Redes Neuronales Artificiales (ANN) y Soporte Vectorial de Regresión (SVR), (STL + XGBoost), regresión lasso, el bosque aleatorio, LSTM, ARIMA. En el área de vacunación: IHBA, ARIMA y XGBoost, GRU, Random Forest Regressor (RFR). En el área farmacéutica (Medicamentos): GRU, LSTM, Random Forest, LSTM. En el área de hospitalización: XGBoost, Long Short-Term Memory (LSTM) y ANFIS. En el área de Emergencias: Redes Neuronales Artificiales (ANN), Recursively Imputed Survival Tree (RIST), Cox Regression, Hybrid Cox-Artificial Neural Network (Cox-ANN), Red Neuronal Convolutiva de Gráfico Bipartito (BiGCN), LightGBM, DNN-I-GA y XGBoost. En el área de epidemiología: Campo Neural Bayesiano (BAYESNF). Sin embargo, los estudios coinciden en la necesidad de ampliar los conjuntos de datos con información más dinámica y en tiempo real, incorporar factores externos (epidemiológicos, demográficos y geoespaciales) y validar los modelos en diferentes contextos y poblaciones. Entre las oportunidades identificadas se encuentran la integración de estas técnicas en los sistemas de salud para optimizar la asignación de recursos y mejorar la planificación en situaciones de crisis como pandemias, el desarrollo de herramientas de apoyo a la decisión clínica y la reducción de inequidades en el

acceso a la atención, consolidando así el potencial del machine learning como un aliado estratégico en la gestión y predicción de la demanda en salud.

Tabla 3. *Algoritmos con mejor rendimiento usados en distintas áreas de la salud*

<b>Área de la salud</b>	<b>Algoritmos o modelos de ML</b>
Cuidados intensivos (UCI)	BILSTM, GASVR, ANFIS, XGBoost, Redes Neuronales Artificiales (ANN), Regresión por Vector de Soporte (SVR), Redes neuronales autorregresivas (ARNN), Redes neuronales artificiales tradicionales (ANN)
Servicios médicos (atención a ancianos, pacientes crónicos, etc.)	LightGBM, Regresión Logística (LR), Análisis Discriminante Cuadrático (QDA), XGBoost (XGB), Multi-Task Learning (MTL), Stacked autoencoders (SAE), Fidan (combinación de LightGBM y el algoritmo SHAP), Random Forest
Distribución y suministro de sangre	LSTM-XGBoost, Random Forest y XGBoost, Redes Neuronales Artificiales (ANN), Soporte Vectorial de Regresión (SVR), STL + XGBoost, Regresión Lasso, Bosque aleatorio, LSTM, ARIMA
Vacunación	IHBA, ARIMA, XGBoost, GRU, Random Forest Regressor (RFR)
Farmacéutica (Medicamentos)	GRU, LSTM, Random Forest
Hospitalización	XGBoost, Long Short-Term Memory (LSTM), ANFIS
Emergencias	Redes Neuronales Artificiales (ANN), Recursively Imputed Survival Tree (RIST), Cox Regression, Hybrid Cox-Artificial Neural Network (Cox-ANN), Red Neuronal Convolutacional de Gráfico Bipartito (BiGCN), LightGBM, DNN-I-GA, XGBoost
Epidemiología	Campo Neural Bayesiano (BAYESNF)

*Nota.* Elaboración propia a partir de la revisión de literatura.

Además, se identifican oportunidades para futuros trabajos que incluyan una base bibliográfica más amplia y permitan clasificar de manera más detallada los usos de los diferentes algoritmos, dado que el empleo del machine learning en la predicción de la demanda de servicios de salud está creciendo exponencialmente y la producción de artículos científicos en esta área continúa en aumento en la actual era tecnológica. Asimismo, los estudios futuros podrían explorar con mayor profundidad modelos híbridos que combinen aprendizaje supervisado y no supervisado, con el fin de obtener resultados más robustos y generalizables. En este sentido, el presente trabajo no solo aporta un panorama exploratorio del estado del arte, sino que también constituye una base para futuras investigaciones y una herramienta útil para el avance de la aplicación del machine learning en el campo de la salud.

## Agradecimiento

Le doy primeramente gracias a Dios, a mis padres, abuelos, hermanos, directora de tesis y a todas las personas que hicieron posible que llegara hasta este punto de mi vida. También agradezco a la Universidad Industrial de Santander por brindarme las herramientas y el conocimiento necesarios para desempeñarme en la vida laboral y personal.

## REFERENCIAS

1. M. Abdel-salam, M. Elhoseny, and I. M. El-hasnony, *Intelligent and Secure Evolved Framework for Vaccine Supply Chain Management Using Machine Learning and Blockchain*, SN Computer Science, vol. 6, no. 2, 2025. <https://doi.org/10.1007/s42979-024-03609-3>
2. W. Ben Elmira, A. Hemmak, and B. Senouci, *Smart Platform for Data Blood Bank Management: Forecasting Demand in Blood Supply Chain Using Machine Learning*, Information (Switzerland), vol. 14, no. 1, 2023. <https://doi.org/10.3390/info14010031>
3. S. S. Bhat, V. R. Srihari, A. Prabhune, S. S. Satheesh, and A. B. Bidrohi, *Optimizing Medication Access in Public Healthcare Centers: A Machine Learning Stochastic Model for Inventory Management and Demand Forecasting in Primary Health Services*, Proc. 2nd Int. Conf. on Intelligent and Innovative Technologies in Computing, Electrical and Electronics (ICIITCEE), 2024. <https://doi.org/10.1109/IITCEE59897.2024.10467229>
4. T. Butsingkorn, A. Apichottanakul, and S. Arunyanart, *Predicting Demand For Emergency Ambulance Services: A Comparative Approach*, Journal of Applied Science and Engineering, vol. 27, no. 10, pp. 3313–3318, 2024. [https://doi.org/10.6180/jase.202410\\_27\(10\).0011](https://doi.org/10.6180/jase.202410_27(10).0011)
5. C. Y. Cheng, K. L. Chiang, and M. Y. Chen, *Intermittent Demand Forecasting in a Tertiary Pediatric Intensive Care Unit*, Journal of Medical Systems, vol. 40, no. 10, 2016. <https://doi.org/10.1007/s10916-016-0571-9>
6. S. C. Chien, Y. H. Chang, C. M. Yen, Y. E. Chen, C. C. Liu, Y. P. Hsiao, P. Y. Yang, H. M. Lin, X. H. Lu, I. C. Wu, C. C. Hsu, H. Y. Chiou, and R. H. Chung, *Predicting Long-Term Care Service Demands for Cancer Patients: A Machine Learning Approach*, Cancers, vol. 15, no. 18, 2023. <https://doi.org/10.3390/cancers15184598>
7. E. Dulce-Chamorro, and F. J. Martinez-de-Pison, *An advanced methodology to enhance energy efficiency in a hospital cooling-water system*, Journal of Building Engineering, vol. 43, 2021. <https://doi.org/10.1016/j.jobbe.2021.102839>
8. A. El Filali, E. H. B. Lahmer, S. El Filali, M. Kasbouya, M. A. Ajouary, and S. Akantous, *Machine Learning Applications in Supply Chain Management: A Deep Learning Model Using an Optimized LSTM Network for Demand Forecasting*, Int. J. of Intelligent Engineering and Systems, vol. 15, no. 2, pp. 464–478, 2022. <https://doi.org/10.22266/ijies2022.0430.42>
9. Y. N. Feng, Z. H. Xu, J. T. Liu, X. L. Sun, D. Q. Wang, and Y. Yu, *Intelligent prediction of RBC demand in trauma patients using decision tree methods*, Military Medical Research, vol. 8, no. 1, 2021. <https://doi.org/10.1186/s40779-021-00326-3>
10. M. Goic, M. S. Bozanic-Leal, M. Badal, and L. J. Basso, *COVID-19: Short-term forecast of ICU beds in times of crisis*, PLoS ONE, vol. 16, no. 1, 2021. <https://doi.org/10.1371/journal.pone.0245272>
11. R. Hariharan, J. Sundberg, G. Gallino, A. Schmidt, D. Arenth, S. Sra, and B. Fels, *An Interpretable Predictive Model of Vaccine Utilization for Tanzania*, Frontiers in Artificial Intelligence, vol. 3, 2020. <https://doi.org/10.3389/frai.2020.559617>
12. H. Hassanzadeh, J. Boyle, S. Khanna, B. Biki, and F. Syed, *Daily surgery caseload prediction: towards improving operating theatre efficiency*, BMC Medical Informatics and Decision Making, vol. 22, no. 1, 2022. <https://doi.org/10.1186/s12911-022-01893-8>
13. H. Hu, J. Xu, M. Liu, and M. K. Lim, *Vaccine supply chain management: An intelligent system utilizing blockchain, IoT and machine learning*, Journal of Business Research, vol. 156, 2023. <https://doi.org/10.1016/j.jbusres.2022.113480>
14. Y. Huang, T. Xu, Q. Yang, C. Pan, L. Zhan, H. Chen, X. Zhang, and C. Chen, *Demand prediction of medical services in home and community-based services for older adults in China using machine learning*, 2023.
15. F. Hutter, L. Kotthoff, and J. Vanschoren, *Automated Machine Learning Methods, Systems, Challenges*, The Springer Series on Challenges in Machine Learning, 2019. <http://www.springer.com/series/15602>
16. Instituto Nacional de Salud, J. P. Uribe Restrepo, M. L. Ospina Martínez, C. A. Durán Camacho, and C. A. Castañeda-Orjuela, *Acceso a servicios de salud en Colombia*, 2019.
17. S. Jiang, K. S. Chin, and K. L. Tsui, *A universal deep learning approach for modeling the flow of patients under different severities*, Computer Methods and Programs in Biomedicine, vol. 154, pp. 191–203, 2018. <https://doi.org/10.1016/j.cmpb.2017.11.003>
18. R. Jin, T. Xia, X. Liu, T. Murata, and K. S. Kim, *Predicting Emergency Medical Service Demand with Bipartite Graph Convolutional Networks*, IEEE Access, vol. 9, pp. 9903–9915, 2021. <https://doi.org/10.1109/ACCESS.2021.3050607>
19. L. D. Lam, B. P. Le Luong, H. T. Mai Linh, and P. M. Hung, *Application of Machine Learning in Predicting the Amount of Pharmaceutical Drugs Ordered for the Manufacturer*, 1st Int. Conf. on Health Science and Technology (ICHST), 2023. <https://doi.org/10.1109/ICHST59286.2023.10565367>
20. N. Li, F. Chiang, D. G. Down, and N. M. Heddle, *A decision integration strategy for short-term demand forecasting and ordering for red blood cell components*, Operations Research for Health Care, vol. 29, 2021. <https://doi.org/10.1016/j.orhc.2021.100290>
21. A. X. Lin, A. F. W. Ho, K. H. Cheong, Z. Li, W. Cai, M. L. Chee, Y. Y. Ng, X. Xiao, and M. E. H. Ong, *Leveraging machine learning techniques and engineering of multi-nature features for national daily regional ambulance demand prediction*, Int. J. of Environmental Research and Public Health, vol. 17, no. 11, 2020. <https://doi.org/10.3390/ijerph17114179>
22. F. Mbonyinshuti, J. Nkurunziza, J. Niyobuhungiro, and E. Kayitare, *Health supply chain forecasting: a comparison of ARIMA and LSTM time series models for demand prediction of medicines*, Acta Logistica, vol. 11, no. 2, pp. 269–280, 2024. <https://doi.org/10.22306/AL.V11I2.510>
23. Ministerio de Salud y Protección Social, A. Jaramillo Martínez, H. Urrego Rodríguez, A. Martínez Saldarriaga, E. Salas Figueroa, L. A. Zuluaga Salazar, R. R. Castro Contreras, M. Y. Camelo Romero, Y. P. Torres Castro, and A. Mahecha Acosta, *Informe de gestión social 2023*, Ministerio de Salud y Protección Social, 2023.
24. M. Motamedi, J. Dawson, N. Li, D. G. Down, and N. M. Heddle, *Demand forecasting for platelet usage: From univariate time series to multivariable models*, PLoS ONE, vol. 19, no. 4, 2024. <https://doi.org/10.1371/journal.pone.0297391>
25. Z. Obermeyer, and E. J. Emanuel, *Predicting the Future — Big Data, Machine Learning, and Clinical Medicine*, New England Journal of Medicine, vol. 375, no. 13, pp. 1216–1219, 2016. <https://doi.org/10.1056/nejmp1606181>

26. M. H. Olya, H. Badri, S. Teimoori, and K. Yang, *An integrated deep learning and stochastic optimization approach for resource management in team-based healthcare systems*, *Expert Systems with Applications*, vol. 187, 2022. <https://doi.org/10.1016/j.eswa.2021.115924>
27. Organización Panamericana de la Salud, *Salud en las Américas 2022*, 2022.
28. J. M. Pineda, *Predictive models in health based on machine learning*, *Revista Médica Clínica Las Condes*, vol. 33, no. 6, pp. 583–590, 2022. <https://doi.org/10.1016/j.rmclc.2022.11.002>
29. A. Pushmika, T. Naragala, P. K. W. Abeygunawardhana, Y. Wijesekara, V. Muthukudaarachchi, and R. Liyanage, *Predictive Analytics for Blood Supply Chain Management and Data Security in Healthcare System*, *ICAC 2023 - 5th Int. Conf. on Advancements in Computing*, pp. 292–297, 2023. <https://doi.org/10.1109/ICAC60630.2023.10417194>
30. K. Riazi, M. Ly, R. Barty, J. Callum, D. M. Arnold, N. M. Heddle, D. G. Down, D. Sidhu, and N. Li, *An unsupervised learning approach to identify immunoglobulin utilization patterns using electronic health records*, *Transfusion*, vol. 63, no. 12, pp. 2234–2247, 2023. <https://doi.org/10.1111/trf.17585>
31. F. Saad, J. Burnim, C. Carroll, B. Patton, U. Köster, R. A. Saurous, and M. Hoffman, *Scalable spatiotemporal prediction with Bayesian neural fields*, *Nature Communications*, vol. 15, no. 1, 2024. <https://doi.org/10.1038/s41467-024-51477-5>
32. F. Salamian, A. Paksaz, B. Khalil Loo, M. Mousapour Mamoudan, M. Aghsami, and A. Aghsami, *Supply Chains Problem During Crises: A Data-Driven Approach*, *Modelling*, vol. 5, no. 4, pp. 2001–2039, 2024. <https://doi.org/10.3390/modelling5040104>
33. N. Sen, L. O. Temur, and D. C. Atilla, *Yellow Fever Vaccine Demand Forecasting With ARIMA, SARIMA, Linear Regression, and XGBoost*, *IEEE Access*, vol. 12, pp. 197557–197576, 2024. <https://doi.org/10.1109/ACCESS.2024.3517652>
34. S. Shafiekhani, P. Namdar, and S. Rafiei, *A COVID-19 forecasting system for hospital needs using ANFIS and LSTM models: A graphical user interface unit*, *Digital Health*, vol. 8, 2022. <https://doi.org/10.1177/20552076221085057>
35. M. Singh, J. Liu, L. Kirkland, and J. Srivastava, *Decompensation Prediction for Hospitalized COVID-19 Patients*, *Proc. 2022 IEEE 10th Int. Conf. on Healthcare Informatics (ICHI)*, pp. 502–504, 2022. <https://doi.org/10.1109/ICHI54592.2022.00088>
36. M. Soltani, M. Farahmand, and A. R. Pourghaderi, *Machine learning-based demand forecasting in cancer palliative care home hospitalization*, *Journal of Biomedical Informatics*, vol. 130, 2022. <https://doi.org/10.1016/j.jbi.2022.104075>
37. J. Todd, A. Gepp, S. Stern, and B. J. Vanstone, *Improving decision making in the management of hospital readmissions using modern survival analysis techniques*, *Decision Support Systems*, vol. 156, 2022. <https://doi.org/10.1016/j.dss.2022.113747>
38. G. Yang, G. Wang, L. Wan, X. Wang, and Y. He, *Utilizing SMOTE-TomekLink and machine learning to construct a predictive model for elderly medical and daily care services demand*, *Scientific Reports*, vol. 15, no. 1, 2025. <https://doi.org/10.1038/s41598-025-92722-1>
39. R. R. Zebari, G. M. Zebari, A. Al-zebari, and M. A. Mohammed, *LSTM-XGBoost: An Ensemble Model for Blood Demand Distribution Forecasting – A Case Study in Zakho City, Kurdistan Region, Iraq*, *Operations Research Forum*, vol. 6, no. 1, 2025. <https://doi.org/10.1007/s43069-024-00413-w>
40. W. Zhang, and X. Li, *A data-driven combined prediction method for the demand for intensive care unit healthcare resources in public health emergencies*, *BMC Health Services Research*, vol. 24, no. 1, 2024. <https://doi.org/10.1186/s12913-024-10955-8>
41. F. Zhou, X. Du, W. L. Li, Z. Lu, and S. C. Huang, *Fidan: a predictive service demand model for assisting nursing home health-care robots*, *Connection Science*, vol. 35, no. 1, 2023. <https://doi.org/10.1080/09540091.2023.2267791>
42. S. G. V. Zirbo, B. S. Hoszu, L. S. Diosan, A. M. Coroiu, and A. E. Croitoru, *Predicting Health Outcomes using Weather Data: A Dual Machine Learning Approach*, *Procedia Computer Science*, vol. 246(C), pp. 1399–1408, 2024. <https://doi.org/10.1016/j.procs.2024.09.721>