

Modelo de pronóstico para anticipar los niveles de ocupación del servicio de
hospitalización en la FOSCAL

Oscar Mauricio Ruiz Alava

Trabajo de Grado para Optar el Título de Especialista en estadística

Director

Heivar Yesid Rodríguez Pinzón

Magister en ciencias económicas

Universidad Industrial de Santander

Facultad de ciencias

Escuela de matemáticas

Especialización en estadística

Bucaramanga

TABLA DE CONTENIDO

Introducción	8
1. Descripción del problema	9
2. Antecedentes	10
3. Justificación	11
4. Objetivos	13
4.1 Objetivo General	13
4.2 Objetivos Específicos	13
5. Marco teórico	14
5.1 Marco Referencial	14
5.2 Marco Conceptual	18
5.2.1 Ocupación hospitalaria	18
5.2.2 Modelos predictivos	18
5.2.3 Modelos de suavizamiento exponencial (ETS)	19
5.2.4 Modelo ARIMA, SARIMA y ARIMAX.	20
5.2.5 Modelo de regresión con errores ARMA	21
5.2.6 Modelos multivariados VAR y VARX	22
5.2.7 Modelos Prophet	22
5.2.8 Modelos de aprendizaje profundo LSTM y GRU	23
5.2.9 Series temporales	24
5.2.10 Modelo estructural bayesiano (BSTS)	28
5.2.11 Gestión hospitalaria	31

5.3 Marco Legal	31
6. Metodología	33
6.1 Tipo de investigación	33
6.2 Población y muestra	33
6.3 Descripción de variables	34
7. Resultados	35
7.1 Análisis descriptivo	35
7.1.1 Descripción de variables cualitativas	35
7.1.2 Descripción de variables cuantitativas	36
7.2 Pronóstico para la hospitalización ginecobstetricia	50
7.3 Pronóstico para la hospitalización UCI Adultos	56
7.3 Pronóstico para la hospitalización UCI Pediátrica	62
8. Conclusiones	69
9. Referencias	70

LISTA DE TABLAS

Tabla 1	16
Tabla 2	23
Tabla 3	34
Tabla 4	37
Tabla 5	38
Tabla 6	51
Tabla 7	53
Tabla 8	55
Tabla 9	57
Tabla 10	59
Tabla 11	60
Tabla 12	63
Tabla 13	65
Tabla 14	67

LISTA DE FIGURAS

Fig. 1	40
Fig. 2	41
Fig. 3	42
Fig. 4	44
Fig. 5	45
Fig. 6	47
Fig. 7	48
Fig. 8	52
Fig. 9	58
Fig. 10	64

Resumen

Título: Modelo de pronóstico para anticipar los niveles de ocupación en el servicio de hospitalización en la fundación oftalmológica de Santander FOSCAL.

Autor: Oscar Mauricio Ruiz Alava

Palabras Clave: Ocupación hospitalaria, modelos predictivos bayesianos, series temporales

Descripción: Este proyecto propone el desarrollo e investigación de un modelo predictivo bayesiano estructural (BSTS) enfocado en anticipar los niveles de ocupación del servicio de hospitalización en la fundación oftalmológica de Santander FOSCAL. La demanda creciente de atención hospitalaria converge hacia retos operativos en la optimización de recursos asistenciales claves como las camas disponibles, por lo cual se hace necesario el uso de una herramienta estadística que permita anticipar escenarios de saturación y que sirva como apoyo en la toma de decisiones estratégicas dentro de la institución.

La investigación estará sustentada por un análisis exhaustivo de datos históricos anonimizados correspondientes al porcentaje de ocupación mensual comprendido entre los años 2021 al 2024. Se aplicará un enfoque bayesiano que capture tendencia, estacionalidad y variabilidad en los patrones de ocupación. El resultado del modelo será validado utilizando métricas de desempeño como el error medio absoluto (MAE) y la raíz del error cuadrático medio (RMSE), garantizando precisión y confiabilidad en las predicciones.

* Trabajo de Grado

** Facultad de Ciencias. Escuela de matemáticas. Director: Heivar Yesid Rodríguez Pinzón. Magister en ciencias económicas.

Abstract

Title: Predictive Model to Anticipate Occupancy Levels in the Hospitalization Service of the Fundación Oftalmológica de Santander FOSCAL

Author: Oscar Mauricio Ruiz Alava

Key Words: Hospital occupancy, bayesian predictive models, time series

Description: This project proposes the development and investigation of a Bayesian Structural Time Series (BSTS) predictive model focused on anticipating occupancy levels in the hospitalization service of the Fundación Oftalmológica de Santander FOSCAL. The increasing demand for hospital care presents operational challenges in optimizing key healthcare resources, such as the availability of hospital beds. Therefore, it is necessary to employ a statistical tool capable of anticipating saturation scenarios and supporting strategic decision-making within the institution.

The research is supported by a comprehensive analysis of anonymized historical data corresponding to the monthly occupancy percentage between 2021 and 2024. A Bayesian approach will be applied to capture trends, seasonality, and variability in occupancy patterns. The model's performance will be validated using statistical metrics such as the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE), ensuring precision and reliability in the predictions.

* Degree Work

** Faculty of sciences. School of mathematics. Advisor: Heivar Yesid Rodriguez Pinzon. Master of economic sciences.

Introducción

La gestión hospitalaria enfrenta el reto constante de equilibrar la disponibilidad de recursos con una demanda altamente variable. En instituciones de alta complejidad como la FOSCAL, los servicios de hospitalización presentan fluctuaciones en la ocupación de camas debido a factores como la estacionalidad de enfermedades, la atención de urgencias o eventos imprevistos. Cuando estas variaciones no se anticipan, pueden generar saturación, demoras en la atención y disminución en la eficiencia operativa.

Históricamente, la planeación hospitalaria se ha basado en métodos descriptivos o proyecciones lineales que ofrecen una visión retrospectiva, pero no incorporan adecuadamente la incertidumbre ni los cambios estructurales del sistema. En este contexto, surge la necesidad de adoptar enfoques predictivos que permitan pasar de una gestión reactiva a una gestión anticipativa, fortaleciendo la toma de decisiones basada en datos.

Los modelos Bayesianos Estructurales de Series Temporales (BSTS) representan una alternativa metodológica robusta para analizar fenómenos complejos con componentes de tendencia, estacionalidad y variabilidad aleatoria. A diferencia de los enfoques tradicionales, los modelos bayesianos cuantifican la incertidumbre y permiten actualizar el conocimiento conforme se incorporan nuevos datos, lo que los hace especialmente útiles en entornos hospitalarios dinámicos.

Este trabajo propone el desarrollo de un modelo BSTS para anticipar los niveles de ocupación del servicio de hospitalización en la FOSCAL. Su implementación busca mejorar la precisión del pronóstico, optimizar la asignación de recursos y apoyar la planificación estratégica institucional.

1. Descripción del problema

La gestión de la ocupación hospitalaria constituye uno de los ejes estratégicos más relevantes en la administración moderna de los servicios de salud. En la Fundación Oftalmológica de Santander FOSCAL, el control de la ocupación en el servicio de hospitalización se ha basado tradicionalmente en métodos manuales o descriptivos que reflejan el comportamiento histórico de la demanda, pero no permiten anticipar escenarios de alta presión asistencial. Esta limitación afecta la capacidad institucional de planificar de manera preventiva la asignación de camas, el personal médico y los recursos logísticos necesarios para garantizar la continuidad de la atención.

La falta de un modelo predictivo confiable puede derivar en fenómenos de sobreocupación o subutilización, con repercusiones directas sobre la calidad del servicio, el bienestar de los pacientes y la sostenibilidad económica de la institución. En un entorno hospitalario de creciente demanda y recursos limitados, estas ineficiencias pueden generar retrasos en los ingresos hospitalarios, reprogramaciones de cirugías, aumento de tiempos de espera y deterioro en los indicadores de desempeño operativo.

Ante esta problemática, se plantea la necesidad de desarrollar e implementar un modelo predictivo basado en series temporales estructurales bayesianas (BSTS), que permita estimar de manera anticipada los niveles de ocupación hospitalaria y generar alertas tempranas sobre posibles escenarios críticos. Este enfoque, sustentado en modelos estadísticos y en la utilización de datos históricos anonimizados, busca fortalecer la gestión basada en evidencia y optimizar la toma de decisiones dentro del proceso de planeación hospitalaria.

2. Antecedentes

En la literatura científica, la predicción de la ocupación hospitalaria ha sido abordada desde múltiples enfoques metodológicos, abarcando desde los modelos estadísticos clásicos hasta las técnicas de inteligencia artificial. Modelos como ARIMA, Holt-Winters y ARIMAX han sido ampliamente utilizados para proyectar la demanda de camas hospitalarias a corto y mediano plazo, evidenciando su utilidad en contextos con comportamiento estacional. Sin embargo, estos enfoques deterministas presentan limitaciones al capturar relaciones no lineales y al cuantificar la incertidumbre inherente a los sistemas hospitalarios.

En los últimos años, los modelos bayesianos estructurales (BSTS) han adquirido relevancia en la predicción de series temporales en el ámbito hospitalario debido a su capacidad para integrar información previa, capturar relaciones no lineales y estimar la incertidumbre inherente a los sistemas de salud. Un estudio realizado por Schiele, Koperna y Brunner (2020) se constituye como un referente importante en este campo, al aplicar un modelo predictivo basado en redes neuronales y técnicas de simulación bayesiana para estimar la ocupación de camas en unidades de cuidados intensivos (UCI) como apoyo a la programación de quirófanos. Los autores demostraron que la combinación de modelos estadísticos avanzados con información operativa en tiempo real, mejoran significativamente la precisión de las proyecciones y permite optimizar la gestión de recursos críticos. Este enfoque, orientado a anticipar escenarios de alta demanda hospitalaria, sirve como punto de referencia metodológico para el presente proyecto, al evidenciar la utilidad de los modelos bayesianos en la planificación hospitalaria y su aplicabilidad en contextos donde la variabilidad de la demanda y la disponibilidad de camas son factores determinantes en la eficiencia institucional.

A nivel nacional, el uso de técnicas de modelamiento predictivo en la gestión hospitalaria aún es incipiente. Si bien se han realizado esfuerzos en instituciones de gran complejidad, la mayoría se enfoca en análisis retrospectivos sin aplicación operativa inmediata. En este contexto, la presente investigación se constituye en una propuesta innovadora y contextualizada, al desarrollar un modelo predictivo aplicado específicamente al entorno hospitalario de la FOSCAL, con el fin de mejorar la eficiencia operativa, la planeación de recursos y la respuesta institucional ante escenarios de alta demanda asistencial.

3. Justificación

El desarrollo de un modelo predictivo bayesiano para anticipar los niveles de ocupación hospitalaria se justifica tanto desde una perspectiva operativa como científica. Desde el ámbito institucional, esta investigación responde a la necesidad de contar con herramientas analíticas que permitan transitar de una gestión reactiva a una gestión predictiva, fortaleciendo la planeación estratégica del servicio de hospitalización. La posibilidad de anticipar fluctuaciones en la demanda permitirá una asignación más eficiente de camas, personal y recursos, reduciendo la probabilidad de saturación y contribuyendo a la mejora continua de la calidad asistencial.

En el plano científico, la literatura actual en predicción de ocupación hospitalaria se basa mayoritariamente en enfoques determinísticos o frecuentistas (como ARIMA o modelos lineales), los cuales no incorporan adecuadamente la incertidumbre inherente a la dinámica asistencial. El modelo Bayesiano Estructural de Series Temporales (BSTS) ofrece un marco probabilístico flexible que permite capturar componentes de tendencia, estacionalidad y ruido, adaptándose a eventos inesperados y proporcionando intervalos de credibilidad que fortalecen la toma de decisiones.

Desde la perspectiva metodológica, el estudio aporta al desarrollo de modelos estadísticos aplicados a la gestión hospitalaria, integrando la inferencia bayesiana con herramientas de simulación y visualización en R. Este componente técnico fortalece la capacidad institucional para implementar metodologías basadas en evidencia, apoyando la transformación digital y analítica de la FOSCAL.

Finalmente, el impacto social de esta investigación radica en la optimización de los procesos asistenciales que repercuten directamente en la experiencia del paciente. Al reducir los tiempos de espera, mejorar la disponibilidad de camas y aumentar la eficiencia operativa, se favorece la continuidad del cuidado y la equidad en la prestación del servicio. Asimismo, la replicabilidad del modelo propuesto puede beneficiar a otras instituciones del sector salud, promoviendo la adopción de modelos predictivos como herramienta esencial para la gestión sostenible y proactiva de los recursos hospitalarios.

4. Objetivos

4.1 Objetivo General

Desarrollar e implementar un modelo predictivo a partir de fuentes de información como indicadores, resúmenes y bases de datos previamente anonimizadas, este modelo estará enfocado en la correcta gestión clínica, sirviendo como insumo para anticipar los índices de ocupación del servicio de hospitalización en la fundación oftalmológica de Santander FOSCAL.

4.2 Objetivos Específicos

- Analizar las tendencias históricas de la ocupación hospitalaria en la Fundación Oftalmológica de Santander FOSCAL, identificando patrones, variaciones estacionales y factores determinantes mediante el procesamiento estadístico de datos anonimizados correspondientes al periodo 2021–2024.
- Desarrollar un modelo predictivo basado en series de tiempo estructurales bayesianas (BSTS), utilizando técnicas de pronóstico y simulación en el software R, ajustado al contexto operativo y asistencial de la institución.
- Evaluar la precisión y estabilidad del modelo predictivo implementado mediante indicadores estadísticos cuantificables, tales como el Error Medio Absoluto (MAE) y la Raíz del Error Cuadrático Medio (RMSE), documentando los resultados en un informe técnico de validación.

- Determinar niveles críticos de ocupación hospitalaria a partir de los percentiles obtenidos del modelo BSTS, con el fin de generar alertas tempranas y proponer un esquema de planificación proactiva de recursos asistenciales en la institución.

5. Marco teórico

5.1 Marco Referencial

La gestión de la ocupación hospitalaria ha sido objeto de estudio en la literatura científica desde mediados del siglo XX, cuando comenzaron a desarrollarse modelos matemáticos y estadísticos orientados a optimizar la utilización de camas y recursos asistenciales. Inicialmente, se utilizaron modelos determinísticos basados en tasas de ingreso y egreso hospitalario (Phillip, Mullner & Andes, 1984), los cuales permitieron establecer indicadores básicos de eficiencia, aunque limitados en su capacidad de predicción.

Con el avance de la informática y la estadística aplicada, surgieron los modelos de series temporales, especialmente los modelos autorregresivos integrados de medias móviles (ARIMA) y los modelos de suavizamiento exponencial (Holt-Winters), que posibilitaron describir tendencias y estacionalidades en la demanda hospitalaria (Hyndman & Athanasopoulos, 2021). Sin embargo, estos modelos tradicionales asumían estructuras lineales y estacionarias, lo cual restringía su aplicabilidad en contextos donde los datos presentan cambios abruptos o alta incertidumbre, como ocurre en los servicios de salud.

Ante estas limitaciones, emergieron los modelos estructurales bayesianos de series temporales (BSTS), los cuales permiten descomponer la serie en componentes observables y latentes (tendencia, estacionalidad y ruido) bajo un marco probabilístico flexible (Scott & Varian, 2015; Brodersen et al., 2015). Este enfoque integra información previa (priors) y

actualiza las estimaciones conforme se incorporan nuevos datos, generando intervalos de credibilidad que cuantifican la incertidumbre predictiva. En el ámbito hospitalario, esta capacidad resulta esencial para anticipar escenarios de alta demanda, gestionar la disponibilidad de camas y planificar recursos de manera preventiva.

Adicionalmente, investigaciones recientes (Zhang, Li & Liu, 2024; Seo et al., 2024) han confirmado la superioridad de los modelos BSTS frente a los modelos ARIMA tradicionales, al adaptarse a cambios estructurales y ofrecer mejor capacidad de generalización en horizontes de predicción medianos y largos. En instituciones hospitalarias, estos modelos han mostrado resultados prometedores para anticipar la ocupación de camas, proyectar admisiones y evaluar el impacto de políticas de gestión hospitalaria.

En el contexto colombiano, la aplicación de modelos predictivos en salud se encuentra en fase de desarrollo. Las instituciones prestadoras de servicios (IPS) han concentrado sus esfuerzos en la planeación operativa reactiva, con escasa adopción de herramientas predictivas basadas en ciencia de datos. Por ello, la presente investigación busca contribuir a la transición hacia una gestión predictiva basada en evidencia, fortaleciendo la planeación estratégica y el control del riesgo asistencial en la Fundación Oftalmológica de Santander (FOSCAL).

Diversos estudios han abordado el problema del pronóstico de la ocupación hospitalaria utilizando distintos enfoques metodológicos, lo que evidencia el interés global por optimizar la gestión de camas y recursos asistenciales. La literatura muestra una evolución progresiva desde modelos estadísticos clásicos, como ARIMA, hacia metodologías más avanzadas basadas en redes neuronales y enfoques bayesianos, los cuales permiten incorporar la incertidumbre y la dinámica cambiante de los sistemas de salud. La siguiente Tabla 1 resume algunos de los trabajos más representativos, destacando el contexto de aplicación, los métodos empleados y los

principales hallazgos. Esta revisión evidencia que, aunque los modelos tradicionales ofrecen resultados aceptables en contextos estables, los modelos bayesianos brindan una mayor flexibilidad y capacidad de adaptación ante escenarios variables, justificando su implementación en el entorno hospitalario de la FOSCAL.

Tabla 1

Estudios previos sobre modelos predictivos aplicados a la ocupación hospitalaria.

Autor	Contexto	Método principal	Horizonte	Hallazgos clave
(Earnest, 2005)	Ocupación diaria de camas de aislamiento durante el brote de SARS en el Hospital Tan Tock Seng (Singapur).	ARIMA (1,0,3)	Predicción a 3 días; MAPE \approx 5.7 % (entrenamiento) y 8.6 % (validación).	ARIMA mostró buen ajuste para pronósticos a corto plazo en entornos epidémicos, apoyando la planificación de camas.
(Schiele, Koperna, & Brunner, 2020)	Ocupación de unidades de cuidados intensivos asociada a la programación de quirófanos en hospital alemán.	Redes neuronales (enfoque de aprendizaje automático de tres pasos).	Predicciones diarias y semanales comparadas con modelos base.	Integración del pronóstico de UCI al proceso quirúrgico mejoró la eficiencia operativa.
(Lee, Lympelopoulos, Cohen, Wong, & Hughes, 2021)	Censo diario de hospitalizados por COVID-19 en 18 hospitales (EE. UU. y Reino Unido).	Modelos bayesianos jerárquicos (Poisson con procesos latentes AR y GP).	Pronóstico a 2 semanas; comparación con baselines institucionales.	Mejor calibración y desempeño predictivo frente a métodos tradicionales.
(Palmer, Lakhiani, Brett, & Ercole, 2024)	Disponibilidad de camas de cuidados críticos (Critical Care) en hospital del Reino Unido.	Modelos de series temporales y aprendizaje automático.	Horizontes de 1, 7 y 14 días; MAE 1.33 frente a 1.61 de referencia.	Factible pronosticar la ocupación de camas críticas usando datos rutinarios.
(Seo, Kim, & Park,	Tasas de ocupación	LSTM / Bi-LSTM con	Evaluación mediante	LSTM logra predicción

2024)	(BOR) a nivel de sala y habitación hospitalaria, datos horarios.	información estática y dinámica.	MAE a nivel de sala y habitación.	granular de ocupación útil para monitoreo en tiempo real.
(Avinash, Sowjanya, Kumar, & Rao, 2025)	Ocupación de camas en hospitales de salud mental (entorno especializado).	Modelos de series temporales (comparativo).	Múltiples horizontes; validación con métricas de error.	La ocupación es predecible incluso en contextos complejos; utilidad para planeación sectorial.

Los modelos bayesianos estructurales (BSTS) implementados en este estudio demostraron un alto nivel de precisión y estabilidad en la predicción de la ocupación hospitalaria en los servicios de Hospitalización Ginecobstetricia, UCI Adultos y UCI Pediátrica. El enfoque BSTS permite modelar explícitamente componentes estructurales de la serie temporal, como la tendencia, la estacionalidad y la variabilidad aleatoria, lo que contribuye a una representación más realista del comportamiento operativo. En el caso del servicio de Hospitalización Ginecobstetricia, el modelo alcanzó un MAPE de 1.11 %, un MAE de 0.0104 y un RMSE de 0.0143, lo que sugiere una excelente capacidad para anticipar fluctuaciones diarias en la demanda de camas. Para UCI Adultos, los indicadores mostraron un MAPE de 2.94 %, con errores absolutos y cuadráticos igualmente reducidos, mientras que en UCI Pediátrica se obtuvo un MAPE de 3.76 %, evidenciando un desempeño consistente incluso en servicios con mayor variabilidad. Estos resultados reflejan la solidez de los modelos BSTS en entornos asistenciales con comportamientos complejos y dinámicos, y resaltan su potencial para apoyar la planificación operativa, optimizar la asignación de recursos y fortalecer la toma de decisiones en la gestión hospitalaria.

En términos generales, los resultados obtenidos con los modelos BSTS son coherentes con la literatura reciente que demuestra la utilidad de los enfoques bayesianos y estructurales en contextos hospitalarios. Sin embargo, los niveles de error alcanzados en este estudio particularmente los MAPE inferiores al 4 % en los tres servicios se sitúan por debajo de los valores comúnmente reportados por modelos tradicionales como ARIMA o por enfoques de aprendizaje automático aplicados en otros entornos asistenciales. Esto sugiere que, para la dinámica específica de la ocupación hospitalaria de la FOSCAL, la estructura flexible y probabilística del BSTS ofrece una capacidad predictiva más ajustada a la variabilidad real del sistema.

5.2 Marco Conceptual

La investigación se apoya en varios conceptos fundamentales:

5.2.1 Ocupación hospitalaria

indicador que mide el porcentaje de camas ocupadas en un periodo determinado respecto al total disponible. Representa la eficiencia en la utilización del recurso cama y es clave para la planeación hospitalaria (OMS, 2023).

5.2.2 Modelos predictivos

Los modelos predictivos para series temporales son herramientas matemáticas diseñadas para estimar valores futuros a partir de patrones históricos. Un modelo predictivo, según (Shmueli, 2010), combina información pasada y cuando corresponde, variables explicativas adicionales para inferir el comportamiento futuro de un sistema. En el contexto hospitalario, la

ocupación de camas presenta características particulares como tendencia, estacionalidad, eventos atípicos y alta dependencia temporal, lo que exige modelos capaces de capturar estas estructuras dinámicas y cuantificar la incertidumbre asociada al pronóstico.

5.2.3 Modelos de suavizamiento exponencial (ETS)

Constituyen una familia ampliamente utilizada para pronósticos de corto plazo en series con patrones relativamente regulares, su importancia radica en la simplicidad y capacidad para representar nivel, tendencia y estacionalidad mediante ecuaciones de suavizamiento exponencial. La idea central es que los valores recientes tienen mayor peso que los antiguos, lo que permite que el modelo se adapte gradualmente a cambios, el suavizamiento exponencial simple (SES) modela únicamente el nivel de la serie a través de:

$$\ell_t = \alpha y_t + (1 - \alpha)\ell_{\{t-1\}}$$

Donde ℓ_t es el nivel suavizado y $\alpha \in (0,1)$ es el parámetro de suavizamiento. La predicción h pasos adelante es constante:

$$\hat{y}_{\{t+h\}} = \ell_t$$

El modelo de Holt, para series con tendencia, incorpora una segunda ecuación:

$$\ell_t = \alpha y_t + (1 - \alpha)(\ell_{\{t-1\}} + b_{\{t-1\}}), b_t = \beta(\ell_t - \ell_{\{t-1\}}) + (1 - \beta)b_{\{t-1\}}$$

Donde b_t representa la pendiente y la predicción es:

$$\hat{y}_{\{t+h\}} = \ell_t + h b_t$$

Holt–Winters extiende el modelo para series con estacionalidad, incorporando un componente estacional S_t :

$$s_t = \gamma (y_t - \ell_t) + (1 - \gamma)s_{\{t-s\}}$$

con la predicción

$$\hat{y}_{\{t+h\}} = \ell_t + h b_t + s_{\{t+h-s[\frac{h-1}{s}]\}}$$

Estos modelos son apropiados para entornos hospitalarios donde la demanda muestra ciclos predecibles.

5.2.4 Modelo ARIMA, SARIMA y ARIMAX.

La familia ARIMA es una de las metodologías más influyentes en series temporales, estos modelos representan la dependencia temporal mediante componentes autorregresivos (AR), diferenciación (I) y medias móviles (MA). Su importancia radica en su capacidad para capturar estructuras lineales, efectos de autocorrelación y patrones estacionales complejos cuando se extienden a SARIMA y la formulación general del modelo ARIMA(p,d,q) se describe mediante:

$$\phi(B)\nabla^d y_t = \theta(B)\varepsilon_t$$

Donde $\phi(B)$ y $\theta(B)$ son polinomios en el operador de rezago B, y ∇^d representa la diferenciación para eliminar tendencia.

El modelo **SARIMA (P, D, Q)s** incorpora componentes estacionales:

$$\Phi(B^s)\varphi(B)\nabla_s^D\nabla^d y_t = \theta(B^s)\theta(B)\varepsilon_t$$

Cuando se añaden covariables externas, se obtiene el modelo **ARIMAX**, formulado como:

$$\varphi(B)\nabla^d y_t = \theta(B)\varepsilon_t + \beta^1 x_{\{1,t\}} + \beta^2 x_{\{2,t\}} + \dots + \beta_k x_{\{k,t\}}$$

lo cual permite integrar información relevante para la ocupación, como número de cirugías programadas, variaciones epidemiológicas o factores de calendario.

5.2.5 Modelo de regresión con errores ARMA

Estos modelos combinan regresión clásica con una estructura de autocorrelación en los residuos siendo útiles cuando se identifican covariables explicativas claras, pero los errores presentan dependencia temporal no explicada, su formulación es:

$$y_t = \beta^0 + \beta^1 x_{\{1,t\}} + \dots + \beta_k x_{\{k,t\}} + \varepsilon_t$$

Donde ε_t sigue un modelo ARMA(p,q):

$$\varphi(B)\varepsilon_t = \theta(B)u_t$$

Este enfoque permite medir el efecto de factores clínicos u operativos sobre la ocupación, mientras se corrige la autocorrelación residual.

5.2.6 Modelos multivariados VAR y VARX

Los modelos VAR son apropiados cuando múltiples servicios hospitalarios interactúan dinámicamente un posible ejemplo sería como los cambios en la ocupación del servicio de UCI pueden influir en hospitalización general. El modelo VAR(p) se expresa como:

$$Y_t = A^1 Y_{\{t-1\}} + A^2 Y_{\{t-2\}} + \dots + A_p Y_{\{t-p\}} + \varepsilon_t$$

Donde Y_t es un vector de series y e_t son errores multivariados siendo la variante VARX la que adiciona regresores externos, estos modelos permiten entender la interacción entre unidades asistenciales, aunque requieren series largas y estacionarias.

5.2.7 Modelos Prophet

Son modelos aditivos que facilitan la incorporación de tendencias con puntos de quiebre, estacionalidades múltiples y efectos de días especiales o festivos. Su formulación general es:

$$y_t = g(t) + s(t) + h(t) + \varepsilon_t$$

Donde $g(t)$ representa la tendencia piecewise, $s(t)$ las estacionalidades en Fourier y $h(t)$ los efectos puntuales de fechas relevantes. Su facilidad de implementación lo convierte en un punto de partida práctico para escenarios hospitalarios con fuertes efectos de calendario.

5.2.8 Modelos de aprendizaje profundo LSTM y GRU

Las redes LSTM (Long Short-Term Memory) y GRU (Gated Recurrent Unit) pertenecen a la familia de redes neuronales recurrentes que están diseñadas para capturar dependencias de largo plazo y no linealidades complejas, por lo que son útiles cuando existen patrones irregulares y un volumen grande de datos.

Aunque no poseen una formulación cerrada como los modelos clásicos, el funcionamiento básico consiste en actualizar estados de memoria mediante puertas de entrada, salida y olvido, lo que permite retener información relevante a lo largo del tiempo. Su principal limitación es la escasa interpretabilidad, factor crítico en estudios clínicos.

Tabla 2

Comparación general de modelos predictivos para series temporales

Modelos	Representantes	Idea central	Fortalezas	Limitaciones	Usos en ocupación hospitalaria
Suavizamiento Exponencial (ETS)	SES, Holt, Holt–Winters	Actualiza nivel/tendencia/estacionalidad con pesos exponenciales	Fácil de interpretar, rápido, buen desempeño en corto plazo	No capta cambios abruptos, no incorpora covariables	Series estables, patrones regulares, estacionalidad mensual o semanal
Modelos ARIMA	ARIMA(p,d,q), SARIMA(P,D,Q)s	Dependencia temporal lineal + diferenciación para estacionariedad	Muy robusto, clásico, buena línea base	Requiere estacionariedad, poca flexibilidad ante cambios de régimen	Series con patrones regulares y alta autocorrelación

Modelos ARIMAX	ARIMA + regresores	ARIMA con predictores externos	Permite explicar variaciones por factores externos	Complejo si los regresores son ruidosos o correlacionados	Ocupación ligada a cirugías, urgencias o eventos estacionales
Modelos de regresión con errores ARMA	Reg-ARMA	Regresión + autocorrelación residual	Buen equilibrio entre interpretación y ajuste	No captura tendencias complejas	Series con covariables clínicas claras
Modelos VAR/VARX	VAR(p), VARX	Dinámica multivariada entre series	Captura interacción entre servicios	Requiere series largas y estacionarias	Ocupación conjunta entre UCI, hospitalización y urgencias
Prophet	Prophet (Facebook)	Modelo aditivo: tendencia + estacionalidades + festivos	Fácil implementación, buen manejo del calendario	Resultados menos precisos si la serie es muy volátil	Series con festividades y ciclos fuertes
Redes neuronales (LSTM/GRU)	LSTM, GRU	Captura relaciones no lineales y dependencias largas	Gran desempeño con big data, flexible	Opaco (poca interpretabilidad), requiere muchos datos	Instituciones con alto volumen de registros y variabilidad compleja

5.2.9 Series temporales

Las series temporales corresponden a un conjunto de observaciones registradas en intervalos regulares de tiempo y permiten analizar la evolución dinámica de un fenómeno bajo la influencia de su propio comportamiento pasado. Su estudio es fundamental en entornos donde las variaciones no son aleatorias sino dependientes del tiempo, como ocurre en la ocupación hospitalaria. Según (Hyndman & Athanasopoulos, 2021), el análisis de series temporales busca

identificar patrones de tendencia, estacionalidad, ciclos, autocorrelación, efectos de calendario y posibles cambios estructurales, aspectos esenciales para comprender la dinámica de la demanda asistencial.

Un elemento clave en el análisis temporal es la autocorrelación, que describe la relación entre los valores actuales y los valores rezagados de la misma serie. La autocorrelación en un rezago k puede expresarse matemáticamente como:

$$\rho_k = \frac{Cov(y_t, y_{\{t-k\}})}{Var(y_t)}$$

Valores altos de ρ_k indican que la ocupación en un día afecta significativamente la ocupación de días posteriores, lo cual es común en procesos hospitalarios donde existen patrones operativos estables y dependencia temporal marcada. Para identificar esta estructura se utilizan herramientas como la función de autocorrelación (ACF) y la función de autocorrelación parcial (PACF).

Otro concepto fundamental es la estacionariedad, entendida como la propiedad por la cual la media, varianza y autocorrelación de la serie permanecen constantes en el tiempo. Una serie estacionaria y_t cumple con:

$$\begin{aligned} E(y_t) &= \mu \\ Var(y_t) &= \sigma^2 \\ Cov(y_t, y_{\{t-k\}}) &= \gamma_k \end{aligned}$$

Cuando la serie no es estacionaria, suelen aplicarse transformaciones como la diferenciación, que se representa mediante:

$$\nabla y_t = y_t - y_{\{t-1\}}$$

De forma más general para diferencias de orden d :

$$\nabla^d y_t = (1 - B)^d y_t$$

Donde B es el operador de rezago definido como:

$$B y_t = y_{\{t-1\}}$$

La estacionariedad es importante porque permite identificar patrones subyacentes y aplicar técnicas analíticas adecuadas. En series hospitalarias, la no estacionariedad suele reflejar variaciones abruptas por brotes epidemiológicos, aumento de demanda, cambios organizacionales o ampliación de infraestructura.

Las series temporales también presentan componentes estructurales, que pueden separarse mediante técnicas de descomposición. En su forma aditiva, la serie puede representarse como:

$$y_t = T_t + S_t + R_t$$

Donde T_t es la tendencia, S_t la estacionalidad y R_t el componente aleatorio. Esta representación permite evaluar si el comportamiento de largo plazo o los patrones estacionales son responsables de la variabilidad observada. En entornos hospitalarios con estacionalidad marcada por semanas, meses o ciclos respiratorios, esta estructura resulta especialmente útil.

Además, las series temporales pueden estar afectadas por eventos atípicos o shocks, los cuales generan desviaciones abruptas respecto al comportamiento típico. Estos valores pueden detectarse mediante reglas basadas en el rango intercuartílico (IQR), por ejemplo:

$$\text{Outlier si: } y_t < Q1 - 1.5(IQR) \text{ o } y_t > Q3 + 1.5(IQR)$$

Estos eventos pueden corresponder a cierres de servicios, infecciones masivas, cambios de política de admisión, fallas en sistemas o variaciones extraordinarias de demanda. Identificarlos y tratarlos adecuadamente es esencial para obtener un análisis y un pronóstico confiable.

Asimismo, los efectos de calendario juegan un papel central en entornos asistenciales. La ocupación puede variar según fines de semana, días festivos, vacaciones colectivas o ciclos laborales. Estos efectos pueden representarse mediante variables indicadoras.

$$\text{Festivo}_t = 1 \text{ si el día } t \text{ es festivo; } 0 \text{ en caso contrario}$$

Finalmente, las series temporales pueden experimentar *cambios estructurales* o puntos de quiebre, situaciones donde la dinámica estadística del proceso se altera significativamente. Un cambio estructural en el nivel puede representarse como:

$$\begin{aligned} y_t &= \mu_1 \text{ para } t \leq \tau \\ y_t &= \mu_2 \text{ para } t > \tau \end{aligned}$$

donde τ es el punto de quiebre, estos cambios son comunes en hospitales cuando se implementan nuevas políticas, se amplían camas o se modifican rutas asistenciales. En conjunto, el análisis de series temporales permite comprender la dinámica interna del fenómeno, detectar patrones recurrentes, medir la dependencia temporal, identificar shocks y preparar el terreno para modelos predictivos más robustos que consideren la complejidad inherente al comportamiento de la ocupación hospitalaria.

5.2.10 Modelo estructural bayesiano (BSTS)

El Modelo Estructural Bayesiano de Series Temporales (BSTS) constituye un marco estadístico avanzado diseñado para analizar y pronosticar series temporales mediante la representación explícita de sus componentes estructurales. Su fundamento principal radica en la descomposición de la serie en elementos latentes como nivel, tendencia, estacionalidad y efectos asociados a regresores que no se observan directamente pero que determinan el comportamiento dinámico del proceso. A diferencia de los modelos clásicos, el enfoque bayesiano incorpora de manera explícita la incertidumbre mediante distribuciones posteriores, lo que permite generar pronósticos probabilísticos coherentes con la variabilidad real del fenómeno. En contextos como la ocupación hospitalaria, donde existen fluctuaciones abruptas asociadas a cambios epidemiológicos, variaciones operativas o estacionalidad marcada, el BSTS ofrece un marco flexible y altamente interpretativo para entender y anticipar la dinámica del sistema.

La estructura matemática del BSTS se basa en la formulación de un modelo dinámico lineal en espacio de estados, compuesto por una ecuación de observación y una ecuación de estado. La primera describe cómo la observación se deriva de los componentes latentes, mientras que la segunda modela la evolución de estos componentes a lo largo del tiempo. En su forma general, el modelo se expresa como:

$$\begin{aligned} y_t &= F_t' \theta_t + v_t \\ \theta_t &= G_t \theta_{\{t-1\}} + w_t \end{aligned}$$

Donde y_t representa el valor observado de la ocupación, θ_t es el vector de estados latentes, F_t y G_t son matrices que especifican la estructura del modelo, y v_t y w_t son

perturbaciones gaussianas. Esta representación permite modelar procesos complejos cuya evolución depende de mecanismos internos que cambian con el tiempo, manteniendo al mismo tiempo la posibilidad de interpretar cada componente por separado.

Dentro de los componentes más comunes se encuentra **el nivel local**, que captura el valor subyacente o “estado base” del proceso. Este se modela como un paseo aleatorio mediante:

$$y_t = \mu_t + \varepsilon_t$$

$$\mu_t = \mu_{\{t-1\}} + \eta_t$$

permitiendo que el nivel se adapte gradualmente conforme la serie cambia, cuando se requiere modelar una tendencia que evoluciona suavemente, puede extenderse hacia un modelo de tendencia local lineal, que incorpora una pendiente dinámica:

$$y_t = \mu_t + \varepsilon_t$$

$$\mu_t = \mu_{\{t-1\}} + \beta_{\{t-1\}} + \eta_t$$

$$\beta_t = \beta_{\{t-1\}} + \zeta_t$$

Este tipo de tendencia resulta especialmente adecuado en sistemas hospitalarios cuyas capacidades o demandas crecen o decrecen de manera progresiva por cambios poblacionales, institucionales o epidemiológicos.

Otro componente clave es la estacionalidad, que puede modelarse de forma trigonométrica para capturar patrones repetitivos asociados, por ejemplo, a ciclos semanales o mensuales. Matemáticamente, la estacionalidad para un período s puede representarse como:

$$\begin{aligned} [s_{\{t,h\}}] &= \left[\cos\left(\frac{2\pi h}{s}\right) \sin\left(\frac{2\pi h}{s}\right) \right] [s_{\{t-1,h\}}] + [\omega_{\{t,h1\}}] \\ [c_{\{t,h\}}] &= \left[-\sin\left(\frac{2\pi h}{s}\right) \cos\left(\frac{2\pi h}{s}\right) \right] [c_{\{t-1,h\}}] + [\omega_{\{t,h2\}}] \end{aligned}$$

La suma de estos armónicos genera el componente estacional total, esta formulación es estable, suave y adecuada para procesos cíclicos que presentan comportamiento periódico consistente, como ocurre en la hospitalización durante periodos de infección respiratoria, vacaciones o demanda asistencial semanal.

Además de los componentes estructurales, el BSTS permite incorporar regresores externos a través de un esquema bayesiano conocido como *spike-and-slab*, que facilita la selección automática de variables relevantes. En este esquema, cada coeficiente puede activarse o apagarse según la evidencia observada, siguiendo la regla:

$$\beta_j \sim (1 - \gamma_j)\delta_0 + \gamma_j N(0, \tau_j^2)$$

Donde γ_j es un indicador que toma el valor 1 si el regresor j es relevante o 0 en caso contrario. Este mecanismo permite identificar efectos de días festivos, acciones institucionales, demanda en otros servicios o factores epidemiológicos sin sobreajustar el modelo.

La inferencia en BSTS se realiza mediante un enfoque completamente bayesiano que combina el filtro de Kalman y el suavizador para el tratamiento de los estados, junto con algoritmos MCMC para estimar los parámetros y las distribuciones posteriores. Esta combinación permite actualizar la incertidumbre a medida que se observan nuevos datos, generando no solo predicciones puntuales sino distribuciones completas sobre los posibles

valores futuros. Así, el modelo produce intervalos de credibilidad que representan la incertidumbre real del proceso, algo especialmente útil para la toma de decisiones en gestión hospitalaria, donde la capacidad operativa depende no solo del valor esperado sino también del riesgo de saturación.

Finalmente, la evaluación del BSTS se basa en el análisis de los residuos, la cobertura de los intervalos de credibilidad, el desempeño en pronósticos retrospectivos (backtesting) y la coherencia estructural de las componentes estimadas. En entornos hospitalarios, el modelo permite no solo anticipar la ocupación sino comprender sus causas subyacentes, identificar cambios estructurales a lo largo del tiempo e integrar información contextual mediante regresores. Esto convierte al BSTS en una herramienta altamente robusta, interpretable y adecuada para escenarios donde la variabilidad, la incertidumbre y la necesidad de planificación anticipada son elementos centrales.

5.2.11 Gestión hospitalaria

proceso de planeación, organización y control de recursos físicos y humanos en instituciones de salud, orientado a garantizar eficiencia, calidad y sostenibilidad (Chiavenato, 2020).

5.3 Marco Legal

El marco legal del presente proyecto se fundamenta en la normativa colombiana que regula la prestación de servicios de salud, la gestión del riesgo y el manejo de información sensible:

- **Ley 1751 de 2015 (Ley Estatutaria de Salud):** reconoce el derecho fundamental a la salud y promueve la eficiencia y calidad en la prestación de los servicios.
- **Decreto 441 de 2022:** reglamenta la operación del Sistema de Información para la Gestión de Prestadores y el intercambio de información clínica, impulsando el uso de herramientas tecnológicas para la planeación y control operativo.
- **Circular Externa 2021170000004-5 de la Superintendencia Nacional de Salud:** establece lineamientos para la gestión integral del riesgo, incluyendo el riesgo actuarial y operativo, promoviendo el uso de modelos predictivos para mitigar desviaciones en la demanda de servicios.
- **Ley 1581 de 2012 y Decreto 1377 de 2013:** regulan la protección de datos personales y garantizan la confidencialidad de la información utilizada en investigaciones.
- **Resolución 1995 de 1999 y Resolución 839 de 2017:** establecen disposiciones sobre la historia clínica y el manejo ético de la información de los pacientes.

El proyecto se alinea con estos marcos normativos, asegurando el cumplimiento de los principios de confidencialidad, legalidad, autonomía institucional y ética en investigación. Asimismo, refuerza los lineamientos de la Circular Supersalud sobre el uso de modelos predictivos como herramientas de gestión del riesgo asistencial.

6. Metodología

6.1 Tipo de investigación

La presente investigación es de enfoque cuantitativo con un diseño no experimental, longitudinal y aplicado. Se basa en el análisis estadístico de datos históricos provenientes del servicio de hospitalización de la Fundación Oftalmológica de Santander FOSCAL, con el fin de desarrollar un modelo predictivo de ocupación hospitalaria.

El enfoque cuantitativo permite analizar tendencias, relaciones y comportamientos de variables medibles como la ocupación, el número de pacientes y la disponibilidad de camas. El estudio es aplicado, dado que busca generar un modelo predictivo funcional que apoye la gestión operativa institucional; no experimental, porque no se manipulan variables, sino que se observan registros históricos; y longitudinal, ya que examina los cambios temporales entre enero de 2021 y diciembre de 2024.

El modelo propuesto utiliza el método Bayesian Structural Time Series (BSTS) implementado en el lenguaje de programación R, por medio del cual se estiman los componentes de tendencia, estacionalidad y ruido aleatorio de la serie temporal, integrando además variables explicativas (pacientes, días cama disponible y ocupada) para generar pronósticos con incertidumbre cuantificada.

6.2 Población y muestra

El universo del estudio corresponde a bases de datos previamente anonimizadas por el área correspondiente donde se observen los totales relacionados registros históricos disponibles del servicio de hospitalización de la institución entre enero de 2021 y diciembre de 2024. La población de referencia la constituyen específicamente las fuentes de información mensuales de

ocupación hospitalaria, incluyendo variables como fecha del registro, número total de camas disponibles, tipo de servicio, días cama ocupados, días cama disponibles, porcentaje de ocupación y número de pacientes hospitalizados haciendo la salvedad que toda información sensible relacionada a los pacientes o usuarios no estará incluida dentro de las bases de datos para dar cumplimiento a las políticas de protección de datos personales y de privacidad de la historia clínica contenidas dentro de la ley 2015 del 2020, la resolución 1995 de 1999 y la resolución 839 de 2017.

6.3 Descripción de variables

La investigación considera variables cuantitativas derivadas de los reportes mensuales de ocupación. Estas se emplean como entradas del modelo BSTS y como insumo para el análisis descriptivo y predictivo.

Tabla 3

Descripción de las variables usadas en el estudio

Tipo de variable	Nombre	Descripción	Unidad de medida	Naturaleza
Dependiente	% Ocupación	Porcentaje mensual de camas ocupadas respecto al total disponible	Porcentaje (%)	Cuantitativa continua
Independiente	Día cama disponible	Promedio de camas disponibles al mes	Días	Cuantitativa continua
Independiente	Día cama ocupada	Promedio de camas utilizadas al mes	Días	Cuantitativa continua
Independiente	Pacientes	Número total de pacientes hospitalizados en el periodo mensual	Conteo	Cuantitativa discreta

Categorica	Servicio	Tipo de servicio: Hospitalización / Ginecoobstetricia, UCI Adultos, UCI Pediátrica	Categoría	Categorica nominal
Temporal	Fecha	Mes y año de registro	Fecha (Mes- Año)	Cuantitativa discreta

7. Resultados

7.1 Análisis descriptivo

El análisis descriptivo constituye la fase fundamental para comprender el comportamiento histórico y las características inherentes de los datos de ocupación hospitalaria en la Fundación Oftalmológica de Santander FOSCAL. Este análisis permitirá caracterizar la distribución, variabilidad y patrones temporales de las variables bajo estudio, sentando las bases para el posterior desarrollo del modelo predictivo bayesiano. A través de estadísticos de tendencia central, dispersión, forma y técnicas de visualización, se busca identificar patrones estacionales, valores atípicos y relaciones entre variables que puedan influir en la capacidad predictiva del modelo. La interpretación de estos resultados proporcionará resultados valiosos sobre la dinámica operativa del servicio de hospitalización y permitirá validar los supuestos necesarios para la implementación de técnicas multivariadas y de series temporales.

7.1.1 Descripción de variables cualitativas

- **Servicio:** Variable categórica nominal que identifica el tipo de servicio médico analizado. Incluye las categorías Hospitalización / Ginecoobstetricia, UCI Adultos y UCI Pediátrica. Esta variable permitirá realizar análisis comparativos entre los

diferentes servicios y evaluar patrones específicos de ocupación en cada área especializada.

- **Fecha:** Variable de naturaleza temporal que registra la fecha mensual de cada observación, comprendiendo el periodo de enero de 2021 a diciembre de 2024. Esta variable es fundamental para el análisis de tendencias, estacionalidad y la construcción de series temporales.

7.1.2 Descripción de variables cuantitativas

- **Porcentaje de Ocupación:** Variable cuantitativa continua que representa el indicador principal del estudio, expresado como el porcentaje mensual de camas ocupadas respecto al total disponible. Constituye la variable dependiente en el modelo predictivo y refleja la eficiencia en la utilización de los recursos hospitalarios.
- **Día Cama Disponible:** Variable cuantitativa discreta que registra la cantidad de camas disponibles para uso hospitalario. Este indicador opera como variable independiente y refleja la capacidad instalada del servicio.
- **Día Cama Ocupada:** Variable cuantitativa discreta que registra la cantidad de camas efectivamente utilizadas. Representa la demanda real del servicio y se relaciona directamente con el porcentaje de ocupación.
- **Número de Pacientes:** Variable cuantitativa discreta que contabiliza el total de pacientes hospitalizados mensualmente. Este indicador proporciona información sobre el volumen de atención y su relación con la utilización de camas.

Tabla 4

Estadísticos de tendencia central

Servicio	Variable	Mínimo	Máximo	Media	Mediana	Moda
Hospitalización / Ginecoobstetricia	Día cama disponible	6729.00	8661.00	7953.58	7843.50	7655.00
	Día cama ocupada	6072.00	8245.00	7291.46	7214.00	6072.00
	% ocupación	85.67	96.12	91.61	91.69	85.67
	Pacientes	1333.00	2523.00	2031.31	2053.50	1847.00
UCI Adultos	Día cama disponible	672.00	744.00	730.02	743.50	744.00
	Día cama ocupada	584.00	739.00	674.54	677.00	676.00
	% ocupación	79.95	99.33	92.40	92.67	94.76
	Pacientes	66.00	171.00	132.02	136.00	157.00
UCI Pediátrica	Día cama disponible	336.00	496.00	420.25	372.00	372.00
	Día cama ocupada	214.00	485.00	380.69	356.00	321.00
	% ocupación	58.33	98.71	90.06	93.74	87.92

	Pacientes	19.00	56.00	40.54	41.00	29.00
--	-----------	-------	-------	-------	-------	-------

Tabla 5

Medidas de dispersión y forma

Servicio	Variable	Desv.Est	CV (%)	Asimetría	Curtosis
Hospitalización / Ginecoobstetricia	Día cama disponible	513.91	6.46	-0.30	2.29
	Día cama ocupada	578.15	7.93	-0.13	2.00
	% ocupación	2.28	2.49	-0.23	2.63
	Pacientes	270.43	13.31	-0.50	3.09
UCI Adultos	Día cama disponible	19.54	2.68	-1.65	5.44
	Día cama ocupada	36.98	5.48	-0.48	3.53
	% ocupación	4.42	4.78	-0.77	3.53
	Pacientes	25.78	19.53	-0.78	2.97
UCI Pediátrica	Día cama disponible	62.80	14.94	0.16	1.17
	Día cama ocupada	80.12	21.05	-0.33	2.03
	% ocupación	10.13	11.14	-1.86	5.73

	Pacientes	9.58	23.63	-0.21	2.21
--	-----------	------	-------	-------	------


El análisis descriptivo de los indicadores operativos revela patrones diferenciados entre los servicios analizados. En el servicio de Hospitalización/Ginecoobstetricia se observa una alta consistencia operativa, evidenciada por coeficientes de variación reducidos en día cama disponible 6.46% y porcentaje de ocupación 2.49%, lo que refleja una baja variabilidad relativa respecto al promedio.

La media de ocupación del 91.61% sugiere una utilización cercana a la capacidad máxima, respaldada por una asimetría negativa de -0.23, indica una concentración de valores en los rangos altos de ocupación. En contraste, la UCI Pediátrica presenta mayor variabilidad, con un CV del 11.14% en ocupación y 21.05% en día cama ocupada, reflejando variaciones más pronunciadas en la demanda. Destaca su alta curtosis de 5.73 y asimetría negativa marcada -1.86 en el porcentaje de ocupación, características de una distribución leptocúrtica, con predominio de valores elevados, pero presencia de episodios extremos de baja ocupación.

El servicio de UCI Adultos muestra indicadores intermedios, con una ocupación media del 92.40% y CV del 4.78%, lo que evidencia una operación más estable que la pediátrica, aunque ligeramente más variable que hospitalización. La distribución de pacientes presenta asimetrías negativas en todos los servicios, lo que sugiere que, si bien existen periodos de menor demanda, predominan escenarios de alta utilización.

Fig. 1

Boxplot de porcentaje de ocupación por servicio



El diagrama de cajas presentado en la Fig. 1 correspondiente permite visualizar la distribución del porcentaje de ocupación en los tres servicios analizados: Hospitalización/Ginecoobstetricia, UCI Adultos y UCI Pediátrica. De manera general, se evidencia que los tres servicios mantienen niveles elevados de ocupación, con medianas comprendidas entre el 91% y el 95%, lo que denota una utilización intensiva y sostenida de la capacidad instalada. En el servicio de Hospitalización/Ginecoobstetricia, la caja presenta un rango intercuartílico estrecho de aproximadamente entre el 90% y el 93% y ausencia de valores atípicos, reflejando una baja dispersión y, por tanto, una estabilidad operativa consistente.

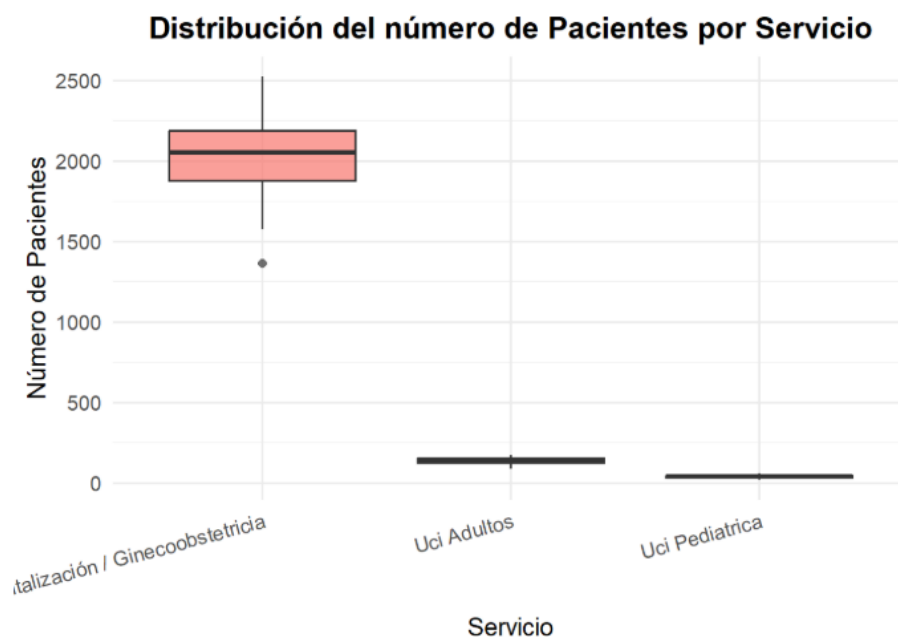
La ligera extensión del bigote inferior sugiere esporádicos episodios de menor ocupación, coherentes con la asimetría negativa moderada observada en el análisis descriptivo.

Por su parte, la UCI de Adultos muestra una mediana superior de aproximadamente 93–94% y una caja de mayor amplitud, lo que indica una variabilidad moderada. Los valores se concentran mayoritariamente en niveles altos, aunque el bigote inferior más extendido evidencia algunos periodos de ocupación reducida. Este comportamiento confirma un patrón de alta demanda con fluctuaciones puntuales, en concordancia con sus coeficientes de variación intermedios y asimetría leve.

Finalmente, la UCI Pediátrica alcanza la mediana más alta aproximadamente de 94–95%, pero muestra una dispersión considerablemente mayor y la presencia de un valor atípico en torno al 80%, lo que sugiere la existencia de eventos excepcionales de baja ocupación. La forma de la caja, junto con dicho outlier, coincide con los estadísticos previamente obtenidos, en particular, una asimetría negativa pronunciada (-1.86) y alta curtosis (5.73) que caracterizan una distribución leptocúrtica con predominio de valores altos y pocos casos extremos hacia la zona baja.

Fig. 2

Boxplot del número de pacientes atendidos por servicio

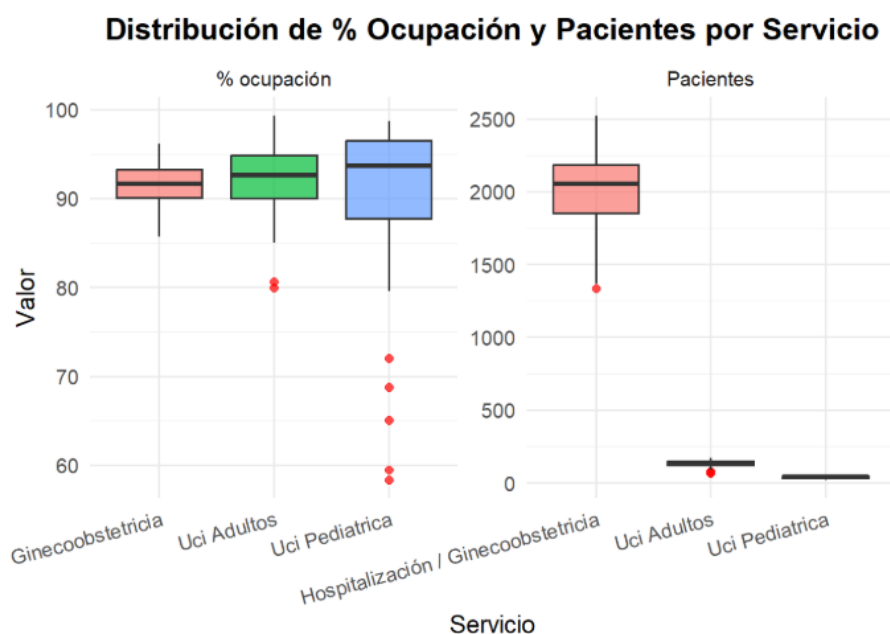


El servicio de Hospitalización/Ginecoobstetricia presenta una distribución concentrada y de valores relativamente altos, con una mediana cercana a los 2.000 pacientes, un rango intercuartílico moderado y un valor atípico en torno a 1.400 pacientes, correspondiente a un episodio puntual de menor demanda. La posición elevada de la caja, junto con la leve asimetría negativa, sugiere una alta capacidad asistencial y estabilidad operativa, respaldando lo evidenciado en los indicadores previos como CV del 13.31% y curtosis de 3.09.

En contraste, tanto UCI Adultos como UCI Pediátrica muestran niveles absolutos de pacientes sustancialmente menores, lo que se traduce en cajas muy próximas al eje inferior del gráfico. Este patrón denota que, aunque la ocupación porcentual de las unidades de cuidado intensivo sea alta, el número total de pacientes atendidos es mucho menor, dado el carácter especializado y la limitada capacidad instalada de camas. Además, la ausencia de valores atípicos visibles y el rango estrecho de ambas cajas indican baja dispersión.

Fig. 3

Distribución de porcentaje de ocupación y pacientes por servicio

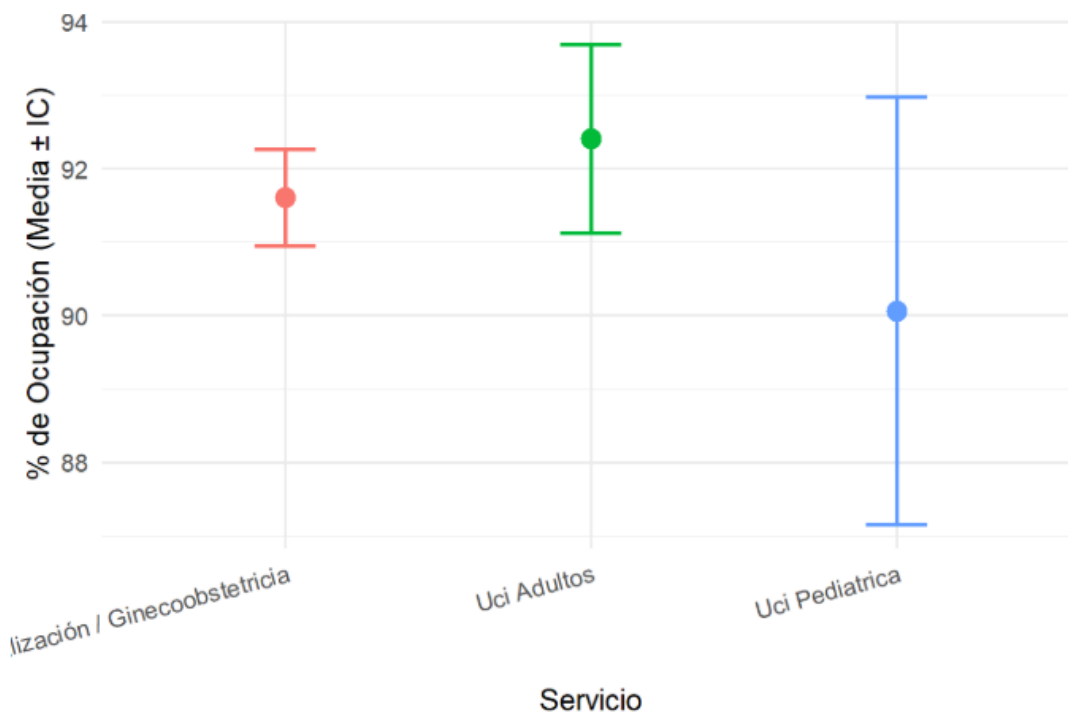


En el panel izquierdo, correspondiente al porcentaje de ocupación, se observa que los tres servicios mantienen niveles medios superiores al 90%, evidenciando una utilización intensiva de la capacidad instalada. No obstante, existen diferencias notables en la dispersión y la presencia de valores atípicos. El servicio de Hospitalización/Ginecoobstetricia exhibe una distribución compacta sin presencia de outliers, lo que refleja estabilidad y regularidad operativa. La UCI de Adultos presenta una caja ligeramente más ancha, lo que indica moderada variabilidad, aunque con valores igualmente concentrados en niveles altos con una mediana cercana al 93%.

La UCI Pediátrica muestra una amplia dispersión y múltiples valores atípicos inferiores, algunos incluso por debajo del 70%, lo que denota mayor inestabilidad, coherente con los altos coeficientes de variación, $CV = 11.14\%$ y la asimetría negativa observada en los indicadores descriptivos. Este comportamiento sugiere que, pese a una tendencia central elevada, el servicio pediátrico experimenta variaciones abruptas en su demanda asistencial. El panel derecho, que representa la distribución del número de pacientes, revela una clara diferencia estructural entre servicios. El servicio de Hospitalización/Ginecoobstetricia concentra el mayor volumen asistencial, con una mediana próxima a los 2.000 pacientes y un único valor atípico en torno a los 1.400, que sugiere un episodio de menor afluencia.

Fig. 4

Intervalos de confianza (IC) al 95% para la media del porcentaje de ocupación



En el servicio de Hospitalización/Ginecoobstetricia, el intervalo de confianza se encuentra estrechamente concentrado alrededor de una media próxima al 91.6%, con límites que apenas oscilan en torno a ± 1 punto porcentual. Esta estrechez del intervalo refleja una baja variabilidad y alta precisión en la estimación, confirmando la estabilidad operativa observada en los análisis previos. El reducido error estándar y la dispersión limitada indican que la ocupación promedio estimada es un valor representativo y confiable del comportamiento real del servicio.

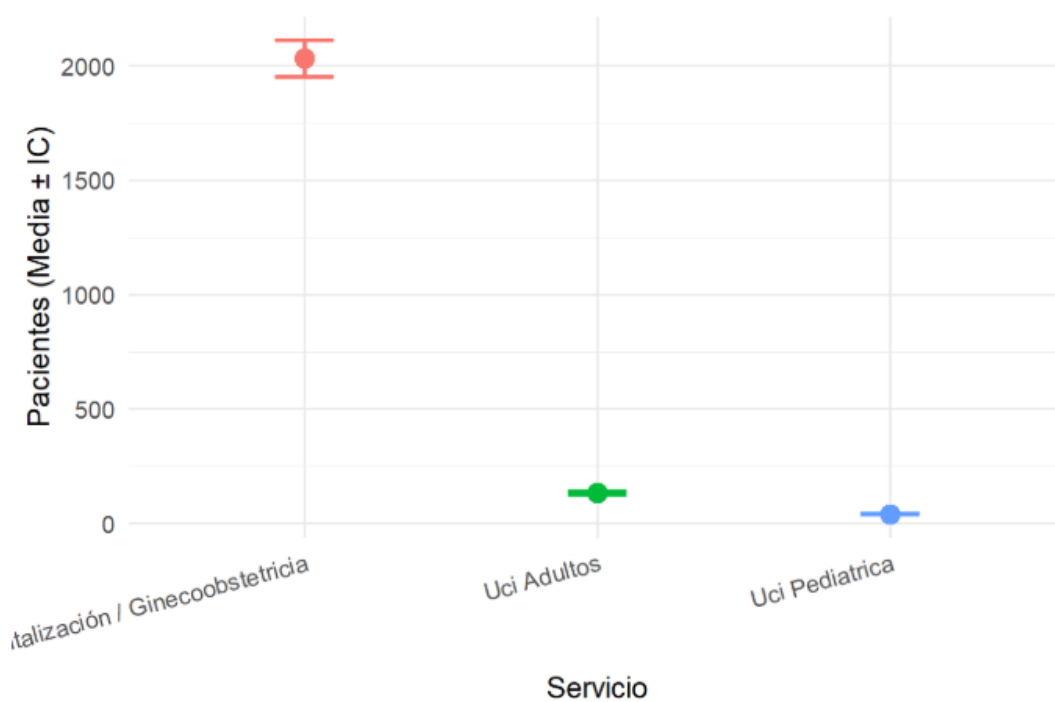
La UCI de Adultos presenta una media ligeramente superior, cercana al 92.4%, acompañada de un intervalo algo más amplio que el de Hospitalización. Este comportamiento sugiere una mayor dispersión de los valores individuales de ocupación, aunque sin perder precisión estadística significativa. La superposición parcial de los intervalos de Hospitalización y UCI Adultos implica que no se puede afirmar con evidencia estadística robusta la existencia de

una diferencia significativa entre ambas medias, lo cual sugiere un rendimiento operativo comparable en términos de utilización de camas.

En contraste, la UCI Pediátrica exhibe un intervalo de confianza considerablemente más amplio, con una media cercana al 90%, pero con límites que se extienden desde aproximadamente 88% hasta 94%. Este amplio rango denota alta incertidumbre estadística en la estimación, atribuible a la mayor variabilidad observada en los datos como el de CV del 11.14% y al menor tamaño de muestra relativo del servicio. La amplitud del intervalo refuerza la evidencia de inestabilidad en la ocupación pediátrica, ya identificada mediante los coeficientes de dispersión y la presencia de outliers en los gráficos anteriores

Fig. 5

Intervalos de confianza (IC) al 95% para la media del número de pacientes

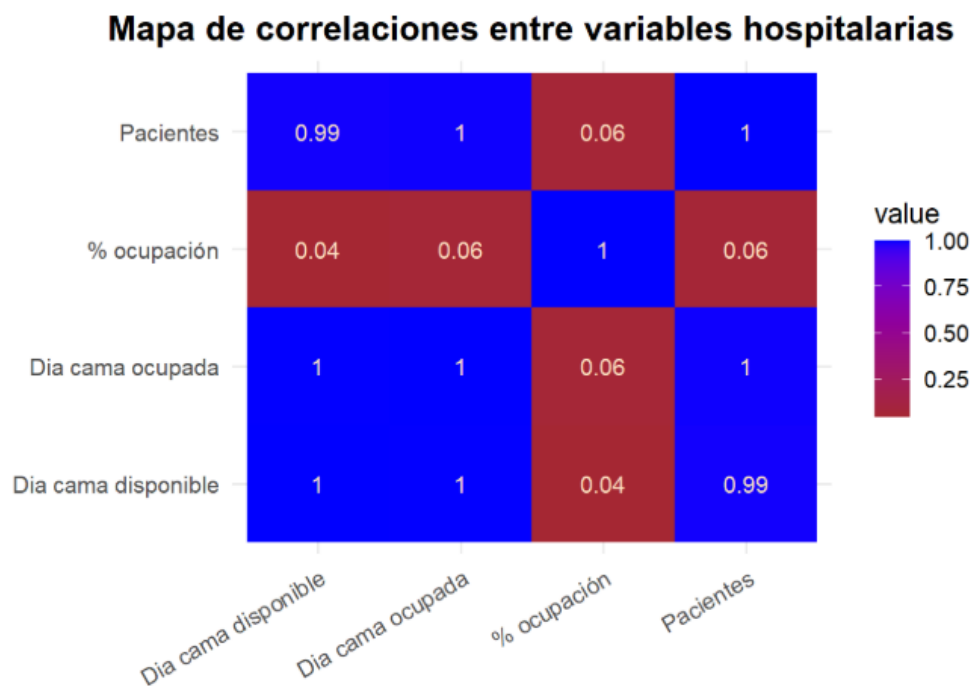


El servicio de Hospitalización/Ginecoobstetricia presenta una media considerablemente superior, cercana a los 2.000 pacientes, con un intervalo de confianza estrecho que refleja baja variabilidad y alta precisión estadística. Esta concentración del intervalo evidencia una gestión estable y sostenida en el volumen de pacientes atendidos, lo que confirma los resultados del análisis descriptivo previo.

La amplitud reducida del IC indica que la media muestral es una estimación confiable del comportamiento poblacional, con escasa incertidumbre asociada. Por otro lado, la UCI de Adultos muestra una media significativamente menor, alrededor de 130 pacientes, con un intervalo también estrecho, lo que sugiere consistencia en el número de ingresos, pese a su baja magnitud absoluta. Este comportamiento es coherente con la naturaleza especializada del servicio y la limitada disponibilidad de camas, donde la atención se concentra en un número reducido pero constante de pacientes críticos. De manera similar, la UCI Pediátrica evidencia un promedio aún más bajo (cercano a 40 pacientes), acompañado igualmente de un intervalo estrecho, lo que indica baja variabilidad dentro del servicio, pero alta disparidad respecto a los otros dos.

Fig. 6

Análisis de correlaciones entre variables hospitalarias



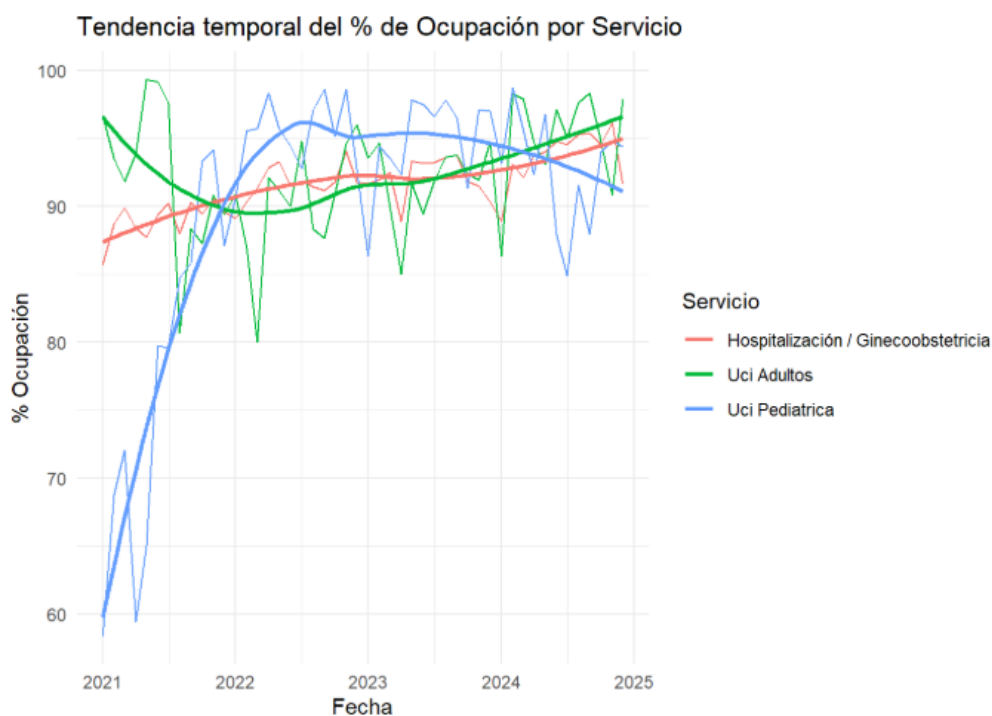
El mapa de correlaciones presentado en la Fig. 6 correspondiente muestra las correlaciones lineales de Pearson entre las variables operativas analizadas: día cama disponible, día cama ocupada, porcentaje de ocupación y número de pacientes. Este análisis permite identificar el grado de asociación entre los indicadores hospitalarios y evaluar la posible redundancia o independencia entre ellos.

Los resultados evidencian correlaciones extremadamente altas ($r \approx 1.00$) entre las variables día cama disponible, día cama ocupada y número de pacientes. Esta relación perfecta o casi perfecta indica que dichas variables evolucionan de manera conjunta, lo que resulta esperable desde una perspectiva operativa: a mayor número de camas disponibles o días cama ocupados, mayor es el volumen de pacientes atendidos.

En términos estadísticos, la correlación cercana a uno sugiere una dependencia casi lineal perfecta, lo cual implica que las tres variables representan esencialmente diferentes manifestaciones de una misma dimensión estructural de capacidad asistencial y flujo de atención hospitalaria. Por otra parte, la correlación entre el porcentaje de ocupación y las demás variables resulta baja, con $r \approx 0.04 - 0.06$, indicando una independencia relativa. Este resultado es coherente con la naturaleza del indicador: el porcentaje de ocupación es una medida relativa de eficiencia en el uso de camas, no un conteo absoluto. Por tanto, aunque el número de camas y pacientes se incremente o disminuya, el porcentaje de ocupación puede mantenerse estable si la relación entre oferta y demanda se conserva proporcional. Desde el punto de vista analítico, esta débil correlación implica que el porcentaje de ocupación captura una dimensión distinta, centrada en la eficiencia operacional y no en la escala de atención.

Fig. 7

Tendencia temporal del porcentaje de ocupación por servicio



La Fig. 7 correspondiente muestra la evolución temporal del porcentaje de ocupación hospitalaria entre los años 2021 y 2025 para los tres servicios analizados: Hospitalización/Ginecoobstetricia, UCI Adultos y UCI Pediátrica. El gráfico combina las series mensuales observadas (líneas delgadas) con curvas suavizadas mediante el método LOESS, que permiten identificar la tendencia subyacente de cada servicio sin verse afectada por la variabilidad de corto plazo. En términos generales, se observa una tendencia ascendente sostenida en los tres servicios, lo cual sugiere un incremento progresivo en la utilización de la capacidad instalada a lo largo del periodo de análisis. No obstante, la magnitud y estabilidad de esta tendencia difieren según el tipo de servicio, evidenciando distintos comportamientos operativos.

El servicio de Hospitalización/Ginecoobstetricia (línea roja) presenta una trayectoria estable y ligeramente creciente, con niveles de ocupación que se mantienen en torno al 90–92% durante la mayor parte del periodo. La suavidad de su curva y la baja amplitud de las fluctuaciones reflejan una operación continua, con alta regularidad y baja variabilidad estacional, probablemente asociada a una demanda constante de servicios obstétricos y ginecológicos.

El incremento gradual al final del periodo sugiere una mejora leve en la eficiencia o una expansión de la demanda controlada. La UCI de Adultos (línea verde) muestra un comportamiento más irregular, caracterizado por oscilaciones marcadas entre periodos de alta y baja ocupación, especialmente en los años 2021 y 2022. Sin embargo, a partir de 2023 se evidencia una recuperación progresiva y una tendencia al alza que converge hacia valores superiores al 92% en 2025. Esta dinámica refleja una adaptación progresiva del servicio, posiblemente en respuesta a cambios en la carga asistencial o en las políticas de gestión de camas críticas.

Las oscilaciones iniciales pueden asociarse a episodios de presión sanitaria coyuntural, mientras que la estabilización posterior sugiere una consolidación operativa. Por su parte, la UCI Pediátrica (línea azul) presenta la evolución más volátil y con mayor amplitud de variación, iniciando con valores bajos, alrededor del 60–70% en 2021 y alcanzando niveles cercanos al 95% en los años recientes. Este comportamiento indica una creciente demanda o utilización del servicio pediátrico crítico a lo largo del tiempo, aunque con marcada inestabilidad intermensual. La elevada dispersión y las caídas puntuales evidencian sensibilidad ante variaciones en la casuística pediátrica o en la disponibilidad de camas, fenómeno característico de unidades de menor tamaño donde pequeñas variaciones en pacientes pueden generar grandes cambios porcentuales. Comparativamente, el análisis temporal revela un proceso de convergencia entre los tres servicios hacia finales del periodo, con niveles de ocupación cercanos o superiores al 90%, lo cual sugiere una utilización generalizada y sostenida de la infraestructura hospitalaria.

7.2 Pronóstico para la hospitalización ginecobstetricia

El modelo aplicado generó pronósticos altamente consistentes con los valores observados del porcentaje de ocupación hospitalaria. Los resultados muestran una correspondencia estrecha entre las observaciones reales (0.9526, 0.9536, 0.9455, 0.9611, 0.9160) y los valores pronosticados por el modelo (0.9427, 0.9512, 0.9535, 0.9588, 0.9452), con diferencias mínimas en el orden de milésimas. Este ajuste preciso indica que el modelo logró una alta capacidad predictiva y una adecuada convergencia, reproduciendo de manera fiel la tendencia de los datos reales. En términos prácticos, la baja desviación entre el pronóstico medio y la observación empírica sugiere que la estructura temporal y la dinámica interna de la ocupación hospitalaria

fueron correctamente capturadas, lo que valida la robustez del modelo para la generación de pronósticos confiables en el contexto analizado.

Tabla 6


Métricas de evaluación hospitalización - ginecobstetricia

Métrica	Símbolo	Valor obtenido
Error porcentual medio absoluto	MAPE	1.11 %
Error absoluto medio	MAE	0.0104
Raíz del error cuadrático medio	RMSE	0.0143

Los resultados evidencian un desempeño predictivo sobresaliente del modelo aplicado al porcentaje de ocupación hospitalaria. El error porcentual medio absoluto, $MAPE = 1.11 \%$, indica que, en promedio, las predicciones difieren menos del 1.2 % respecto a los valores observados, lo que representa un alto nivel de precisión estadística para este tipo de series operativas. De manera complementaria, el error absoluto medio, $MAE = 0.0104$, y la raíz del error cuadrático medio, $RMSE = 0.0143$, reflejan desviaciones mínimas en la escala original de la variable, entre 1 % y 1.5 %, confirmando que el modelo reproduce fielmente las variaciones reales de la ocupación.

Fig. 8

Evolución temporal de la distribución posterior del modelo



La Fig. 8 correspondiente representa la evolución temporal del componente estructural estimado por el modelo BSTS para la serie de porcentaje de ocupación hospitalaria. En el eje horizontal se muestra el tiempo en meses, mientras que el eje vertical refleja los valores estimados del estado latente, asociados al comportamiento dinámico de la ocupación. Las áreas sombreadas en distintos niveles de opacidad corresponden a la distribución posterior de las trayectorias del modelo bayesiano, donde el color negro más intenso indica mayor densidad de probabilidad, mientras que las tonalidades grises más claras representan regiones de menor probabilidad.

Los puntos azules representan las observaciones empíricas reales de la serie, que permiten contrastar visualmente la capacidad del modelo para ajustar los datos observados. Se observa que el modelo logra capturar de manera adecuada la tendencia general de la serie, reproduciendo el patrón de crecimiento gradual del porcentaje de ocupación con oscilaciones

moderadas a lo largo del tiempo. En los primeros periodos, con $t < 10$, el modelo muestra una mayor dispersión en las trayectorias simuladas, reflejada en la amplitud de la banda gris. Esto se asocia al efecto de inicialización característico de los modelos estructurales bayesianos, donde la incertidumbre inicial es elevada hasta que el proceso se estabiliza. A partir del segundo año de la serie, que es aproximadamente después del punto 15 en el eje temporal, la densidad posterior se concentra significativamente alrededor de la media de la distribución, lo que indica una mejora en la precisión predictiva y una reducción progresiva de la varianza posterior. Esto evidencia que el modelo alcanza una fase de convergencia y estabilidad, en la cual las predicciones son más confiables y la incertidumbre se reduce.

La serie observada en puntos azules se mantiene en general dentro del rango de alta densidad, zona negra, confirmando que el modelo se ajusta correctamente a los datos empíricos. Únicamente en los periodos iniciales se aprecian leves desviaciones, particularmente un valor mínimo alrededor del 0.70, las cuales son coherentes con la alta variabilidad registrada en la etapa de arranque. En los periodos posteriores, la correspondencia entre valores observados y estimados se mantiene estrecha, con fluctuaciones suaves en torno a un nivel promedio del 90%, lo que sugiere una representación realista del comportamiento operativo hospitalario.

Tabla 7

Pronostico a 12 meses del porcentaje de ocupación hospitalaria

Mes	Mediana pronosticada (porcentaje de ocupación)	Límite inferior (2.5%)	Límite superior (97.5%)
1	91.6	84.3	98.7
2	93.8	85.4	102.3

3	92.8	82.7	102.6
4	89.8	78.4	101.2
5	93.3	80.4	104.9
6	93.3	78.8	106.4
7	93.5	77.9	106.9
8	93.5	76.6	108.0
9	94.1	76.4	110.0
10	94.0	74.9	111.5
11	94.7	74.7	113.2
12	92.5	71.5	111.6

El pronóstico a 12 meses obtenido mediante el modelo BSTS muestra valores medianos del porcentaje de ocupación comprendidos entre 89.8% y 94.7%, con una media estimada cercana al 93%, lo que indica una tendencia estable y sostenida en niveles altos de utilización hospitalaria. Los intervalos de credibilidad oscilan aproximadamente entre 71.5% y 113.2%, evidenciando que, aunque el modelo anticipa un comportamiento predominantemente alto, persiste un margen de incertidumbre moderado, especialmente hacia los meses finales del horizonte de predicción. Esta amplitud refleja la naturaleza estocástica y dinámica de la demanda hospitalaria, así como el incremento natural de la incertidumbre conforme aumenta el horizonte temporal

Tabla 8

Pronostico a 24 meses del porcentaje de ocupación hospitalaria

Mes	Mediana pronosticada porcentaje de ocupación	Límite inferior (2.5%)	Límite superior (97.5%)
1	91.7	84.4	98.6
2	93.9	84.6	102.5
3	92.8	82.3	102.8
4	89.9	77.6	101.2
5	93.0	80.1	105.8
6	93.3	79.1	106.7
7	93.2	77.6	107.6
8	93.1	76.4	108.4
9	93.7	76.4	110.7
10	93.7	75.0	112.2
11	94.5	75.1	113.8
12	92.2	71.5	112.7
13	91.8	68.8	113.2
14	94.1	70.5	116.4
15	93.1	68.7	116.5
16	89.9	64.2	115.7
17	93.4	65.6	119.8
18	93.4	65.3	120.2
19	93.6	62.5	120.7

20	93.4	62.1	122.6
21	94.2	60.7	124.3
22	94.0	60.6	124.8
23	94.9	59.9	127.9
24	93.0	55.6	126.7

El pronóstico a 24 meses mantiene una ocupación media proyectada en torno al 93 %, con valores medianos que oscilan entre 89.9 % y 94.9 %, lo que evidencia una tendencia estable y sostenida en niveles altos de utilización hospitalaria a lo largo del horizonte bianual. Sin embargo, los intervalos de credibilidad se amplían significativamente con el paso del tiempo: en los primeros meses, los límites fluctúan entre 84 % y 106 %, mientras que hacia el final del periodo se extienden desde aproximadamente 56 % hasta 127 %.

Esta expansión refleja el aumento natural de la incertidumbre en las proyecciones a largo plazo, propio de los modelos bayesianos estructurales, especialmente ante variaciones estacionales o factores externos no observados. En términos generales, el modelo anticipa que la ocupación hospitalaria permanecerá por encima del 90 % durante los próximos dos años, aunque con mayor dispersión en los escenarios futuros, lo que sugiere que, si bien la tendencia global es estable, podrían presentarse variaciones moderadas o episodios de sobreocupación en determinados periodos.

7.3 Pronóstico para la hospitalización UCI Adultos

El modelo aplicado al servicio de UCI Adultos muestra un ajuste predictivo muy satisfactorio. Los valores reales del porcentaje de ocupación (entre 90.8 % y 98.3 %) se

encuentran muy próximos a los valores pronosticados por el modelo (entre 93.9 % y 98.9 %), con diferencias menores al 3 % en todos los casos. Esta proximidad evidencia que el modelo captura adecuadamente la dinámica de ocupación de la UCI Adultos, reproduciendo tanto el nivel promedio como las variaciones temporales del servicio. En términos operativos, el resultado sugiere una ocupación estable y alta, con un comportamiento bien explicado por la estructura temporal modelada, lo que valida su idoneidad para generar pronósticos confiables a corto plazo en este servicio crítico.

Tabla 9


Métricas de evaluación UCI - Adultos

Métrica	Símbolo	Valor obtenido
Error porcentual medio absoluto	MAPE	2.94 %
Error absoluto medio	MAE	0.0281
Raíz del error cuadrático medio	RMSE	0.0321

El modelo de pronóstico aplicado a la UCI Adultos presentó un desempeño estadístico muy favorable. El error porcentual medio absoluto $MAPE = 2.94\%$ indica que, en promedio, las predicciones difieren menos del 3 % respecto a los valores reales de ocupación, lo que representa una alta precisión predictiva para este tipo de serie temporal. Asimismo, el error absoluto medio, $MAE = 0.0281$ y la raíz del error cuadrático medio, $RMSE = 0.0321$ confirman una baja magnitud de error en la escala original de la variable. En conjunto, estas métricas evidencian que el modelo logra reproducir fielmente el comportamiento operativo de la UCI Adultos, garantizando pronósticos robustos, estables y confiables para apoyar la planificación de capacidad hospitalaria en el corto plazo.

Fig. 9

Modelo BSTS aplicado al porcentaje de ocupación UCI Adultos



La Fig. 9 muestra la evolución temporal del componente estructural estimado por el modelo BSTS, aplicado a la serie del porcentaje de ocupación de la UCI Adultos. El eje vertical representa la distribución posterior de los estados latentes, mientras que los puntos azules reflejan los valores observados empíricamente. El modelo captura de manera efectiva la tendencia general y la estacionalidad del comportamiento de la ocupación, con valores que se mantienen en niveles altos mayores al 85 % durante la mayor parte del periodo analizado. En los primeros meses se observa una mayor dispersión en las trayectorias simuladas (área gris más amplia), atribuible a la incertidumbre inicial propia del proceso bayesiano, seguida por una estabilización progresiva en los periodos intermedios y finales, donde las simulaciones se concentran alrededor de los valores observados (área negra más densa).

La coincidencia visual entre los puntos reales y la zona de mayor densidad del modelo indica que las estimaciones presentan un excelente ajuste, con reducida varianza posterior a

medida que avanza la serie temporal. Este comportamiento confirma la convergencia del modelo y la adecuada representación de la dinámica subyacente de la UCI Adultos. En términos prácticos, el modelo describe un nivel de ocupación persistentemente alto, con fluctuaciones regulares, reflejo de una demanda estable y una operación eficiente del servicio.

Tabla 10

Pronóstico a 12 meses del porcentaje de ocupación UCI Adultos

Mes	Mediana pronosticada (% ocupación)	Límite inferior (2.5%)	Límite superior (97.5%)
1	95.0	79.3	111.4
2	97.0	78.1	116.8
3	94.0	72.3	116.7
4	92.8	69.0	119.8
5	91.2	64.3	119.8
6	94.2	63.4	125.2
7	95.6	62.8	128.6
8	94.5	59.3	130.6
9	94.0	58.2	132.7
10	95.1	53.7	137.5
11	94.1	50.8	138.5
12	98.0	51.8	143.5

El modelo proyecta para los próximos 12 meses una ocupación promedio cercana al 94 %, con valores medianos que oscilan entre 91.2 % y 98.0 %, reflejando una tendencia estable y

sostenida en niveles altos de utilización del servicio. Los intervalos de confianza muestran una amplitud progresiva, con límites que van desde 79.3 % hasta 143.5 %, lo que indica una mayor incertidumbre en los horizontes más lejanos, propia de la naturaleza estocástica del modelo bayesiano. En los primeros meses, la concentración del intervalo alrededor de la mediana evidencia una alta precisión predictiva, mientras que la expansión gradual hacia el final del periodo sugiere variabilidad potencial en la demanda o en la disponibilidad de camas. En conjunto, las proyecciones confirman una ocupación críticamente alta, manteniéndose de forma consistente por encima del 90 %, lo que resalta la presión asistencial continua sobre la UCI Adultos y la necesidad de estrategias de planificación y gestión proactiva de capacidad hospitalaria.

Tabla 11

Pronóstico a 24 meses del porcentaje de ocupación UCI Adultos

Mes	Mediana pronosticada (porcentaje de ocupación)	Límite inferior (2.5%)	Límite superior (97.5%)
1	95.5	79.8	110.6
2	97.2	77.7	116.1
3	93.9	71.8	116.8
4	93.4	67.9	118.8
5	91.0	62.8	119.8
6	94.0	63.5	124.6
7	94.9	62.4	127.4
8	94.1	57.4	130.0

9	93.6	56.2	132.5
10	93.8	52.6	136.9
11	92.7	49.9	137.5
12	97.2	50.2	145.6
13	95.8	44.2	145.0
14	97.4	43.2	148.6
15	94.7	37.9	149.0
16	93.3	32.1	152.0
17	91.2	28.2	151.5
18	93.8	28.5	158.5
19	95.4	25.7	160.9
20	94.5	19.9	163.1
21	94.4	17.3	165.9
22	94.5	13.7	170.2
23	94.3	10.9	172.5
24	98.8	11.2	177.8

El modelo proyecta una ocupación media cercana al 94 % para la UCI Adultos durante los próximos 24 meses, con valores medianos que oscilan entre 91.0 % y 98.8 %, lo que confirma una tendencia sostenida y estable en niveles altos de utilización hospitalaria. Esta constancia sugiere que el servicio mantendrá una demanda crítica y continua en el mediano plazo, sin evidencias de descensos significativos en la ocupación. Los intervalos de credibilidad al 95 % muestran un ensanchamiento progresivo a lo largo del horizonte de proyección: en los

primeros meses, los límites se ubican entre aproximadamente 80 % y 125 %, mientras que hacia el final del periodo alcanzan extremos de 11 % a 177 %. Este comportamiento refleja el incremento natural de la incertidumbre en modelos bayesianos al extender el horizonte temporal, producto de la propagación del error y de la sensibilidad ante factores externos no observados. En términos prácticos, los resultados indican que la UCI Adultos permanecerá operando por encima del 90 % de ocupación durante la mayor parte del periodo proyectado, lo cual reafirma una alta presión asistencial sostenida.

7.3 Pronóstico para la hospitalización UCI Pediátrica

El modelo aplicado a la UCI Pediátrica muestra un ajuste aceptable, pero con ligera subestimación sistemática respecto a los valores reales observados. Los porcentajes de ocupación reales que son entre 87.9 % y 94.8 % se comparan con pronósticos promedio que oscilan entre 88.5 % y 90.7 %, evidenciando una diferencia moderada, generalmente inferior a 3 o 4 puntos porcentuales. Este comportamiento indica que el modelo capta adecuadamente la tendencia general de alta ocupación, aunque tiende a subestimar levemente los picos de demanda.

Dado el carácter más variable y sensible del servicio pediátrico donde pequeñas variaciones en el número de pacientes generan cambios proporcionales mayores, estos márgenes de error se consideran estadísticamente aceptables. En conjunto, el modelo reproduce de forma razonable el comportamiento de la serie, mostrando coherencia estructural y capacidad predictiva adecuada para escenarios de corto plazo.

Tabla 12


Métricas de evaluación UCI Pediátrica

Métrica	Símbolo	Valor obtenido
Error porcentual medio absoluto	MAPE	3.76 %
Error absoluto medio	MAE	0.0352
Raíz del error cuadrático medio	RMSE	0.0393

El modelo de pronóstico aplicado a la UCI Pediátrica presenta un buen nivel de ajuste, con un error porcentual medio absoluto MAPE de 3.76 %, lo que indica que, en promedio, las predicciones difieren menos del 4 % respecto a los valores reales. El error absoluto medio MAE = 0.0352 y la raíz del error cuadrático medio RMSE = 0.0393 confirman una baja magnitud de error en la escala original de la variable, equivalente a desviaciones menores a 4 puntos porcentuales en la ocupación. Estos resultados reflejan un modelo predictivo estable y razonablemente preciso, considerando la alta variabilidad característica del servicio pediátrico. Aunque la precisión es ligeramente inferior a la observada en los otros servicios, el modelo captura de forma efectiva la tendencia y nivel general de ocupación, resultando adecuado para pronósticos de corto plazo y para la planificación operativa de recursos en unidades críticas pediátricas.

Fig. 10

Modelo BSTS aplicado al porcentaje de ocupación en UCI Pediátrica



La Fig. 10 muestra la evolución temporal del componente estructural estimado por el modelo BSTS para la serie del porcentaje de ocupación en la UCI Pediátrica. Las zonas sombreadas representan la distribución posterior de las simulaciones del modelo, donde el color negro más intenso indica las trayectorias de mayor probabilidad, y los puntos azules corresponden a los valores reales observados.

En los primeros periodos, en $t < 20$, se observa una alta variabilidad y dispersión en las trayectorias, reflejando una etapa inicial con gran incertidumbre y fluctuaciones marcadas en la ocupación, propias de un servicio con menor número de camas y alta sensibilidad ante cambios de pocos pacientes. Sin embargo, a partir de la mitad de la serie, en $t \approx 25$, la densidad posterior se concentra visiblemente alrededor de la media, lo que evidencia una tendencia de estabilización y convergencia del modelo.

El patrón general muestra una tendencia creciente hasta alcanzar valores cercanos al 90–95 %, con oscilaciones regulares, pero sin desviaciones abruptas, lo que sugiere una normalización del comportamiento operativo de la unidad pediátrica. La correspondencia entre las observaciones y la franja de mayor densidad indica que el modelo ajusta correctamente la estructura temporal y la variabilidad intrínseca de la serie.

En conjunto, los resultados demuestran que el modelo BSTS captura eficazmente la transición desde una fase inestable hacia una etapa de mayor regularidad en la ocupación, ofreciendo una representación robusta del comportamiento dinámico del servicio y una base confiable para la proyección de ocupación en horizontes de 12 a 24 meses.

Tabla 13

Pronóstico a 12 meses del porcentaje de ocupación UCI Pediátrica

Mes	Mediana pronosticada (porcentaje de ocupación)	Límite inferior (2.5%)	Límite superior (97.5%)
1	90.2	72.4	106.3
2	97.2	77.8	116.3
3	95.0	73.5	118.4
4	92.3	67.4	117.8
5	96.8	68.4	126.7
6	92.2	60.8	125.4
7	91.2	54.7	126.8
8	97.1	56.4	135.6
9	93.1	50.7	135.8

10	96.7	46.7	142.8
11	97.6	43.1	148.0
12	97.2	39.8	151.4

El modelo proyecta para los próximos 12 meses una ocupación media cercana al 95 %, con valores medianos que oscilan entre 90.2 % y 97.6 %, lo que refleja una tendencia sostenida y estable en niveles altos de utilización del servicio pediátrico. Este comportamiento confirma la consolidación observada en la etapa reciente de la serie, caracterizada por un uso intensivo y continuo de la capacidad instalada.

Los intervalos de credibilidad muestran un rango que se amplía de manera progresiva, desde 72.4 %–106.3 % en los primeros meses hasta 39.8 %–151.4 % hacia el final del horizonte de predicción. Esta expansión indica un incremento gradual en la incertidumbre conforme se extiende el periodo de pronóstico, lo cual es esperable en modelos bayesianos debido a la propagación del error y a la variabilidad estructural del servicio.

En términos operativos, las proyecciones sugieren que la UCI Pediátrica permanecerá consistentemente por encima del 90 % de ocupación, confirmando una alta presión asistencial y la necesidad de mantener estrategias de gestión flexibles ante posibles fluctuaciones de la demanda. No obstante, la amplitud de los intervalos en los meses más lejanos resalta la importancia de una actualización periódica de las estimaciones para ajustar las decisiones de planificación en función de los datos más recientes.

Tabla 14

Pronóstico a 24 meses del porcentaje de ocupación UCI Pediátrica

Mes	Mediana pronosticada (Porcentaje de ocupación)	Límite inferior (2.5%)	Límite superior (97.5%)
1	90.0	72.8	107.5
2	97.5	77.2	116.7
3	94.9	72.8	117.8
4	92.1	67.5	116.5
5	96.6	68.3	126.5
6	92.0	60.4	123.8
7	90.1	56.1	126.8
8	96.2	57.8	137.3
9	92.8	50.6	137.4
10	95.9	47.8	144.2
11	97.3	46.1	149.1
12	95.9	43.3	153.3
13	92.1	30.9	158.0
14	99.1	33.4	170.9
15	97.1	29.9	173.7
16	94.4	20.0	174.3
17	99.0	18.8	183.2
18	94.7	11.9	185.8
19	93.5	0.1	188.9

20	99.2	-0.4	200.2
21	96.0	-7.8	203.1
22	98.3	-12.3	209.1
23	99.5	-14.8	219.8
24	98.7	-19.8	224.1

El modelo proyecta una ocupación promedio sostenida en torno al 95 % durante los próximos 24 meses, con valores medianos que oscilan entre 90.0 % y 99.5 %, lo que confirma una alta estabilidad y persistencia en la utilización de la capacidad hospitalaria en la UCI Pediátrica. Estos resultados consolidan la tendencia observada en los pronósticos de corto plazo, indicando que el servicio mantendría un nivel de saturación elevado a lo largo del horizonte bianual.

Los intervalos de credibilidad muestran una ampliación progresiva de la incertidumbre conforme aumenta el horizonte temporal: en los primeros meses, las bandas se mantienen dentro de un rango relativamente acotado, mientras que hacia el final del periodo alcanzan valores más extremos. Este ensanchamiento es característico de los modelos bayesianos y refleja la acumulación de incertidumbre asociada a la extrapolación temporal, especialmente en contextos de alta variabilidad pediátrica y limitada capacidad estructural.

8. Conclusiones

Este estudio empleó modelos Bayesianos de Series de Tiempo Estructurales, o BSTS, para predecir la ocupación hospitalaria en tres áreas críticas, como Ginecobstetricia, UCI Adultos, e incluso, UCI Pediátrica. Los hallazgos mostraron un desempeño predictivo notable en los tres servicios, errores porcentuales medios absolutos (MAPE) del 1.11%, 2.94%, y 3.76%, respectivamente, esto confirma la gran aptitud de los modelos para reflejar la dinámica temporal y la variabilidad propia de cada área. Los tres modelos mostraron patrones coherentes de convergencia bayesiana; la incertidumbre fue disminuyendo con el avance de la serie temporal, además hubo una correlación cercana entre valores observados y pronosticados que valida su solidez estructural y su fiabilidad predictiva.

Las proyecciones a 24 meses apuntan a una ocupación hospitalaria alta por mucho tiempo, con valores medianos sobre el 90% en todos los servicios estudiados, específicamente: 93% en Ginecobstetricia, 94% en UCI Adultos, y un 95% en UCI Pediátrica. Esta tendencia persistente indica una alta presión asistencial que demanda estrategias proactivas en la administración de la capacidad hospitalaria, en la optimización de procesos y el desarrollo de protocolos flexibles ante los cambios en la demanda.

La expansión de los intervalos de credibilidad a largo plazo acentúa la necesidad de actualizar regularmente los parámetros de los modelos, utilizando datos más actuales. Además, complementar las predicciones con análisis de escenarios que contemplen la incertidumbre es crucial; esto asegura decisiones bien fundamentadas y una planificación estratégica sólida para mantener la calidad de la atención médica.

9. Referencias

- Avinash, G., Sowjanya, T., Kumar, M. R., & Rao, B. S. (2025). Time series forecasting of bed occupancy in mental health hospitals. *BMC Health Services Research*, 101.
- Brodersen, K. H., Gallusser, F., Koehler, J., Remy, N., & Scott, S. L. (2015). Inferring causal impact using Bayesian structural time-series models. *The Annals of Applied Statistics*, 247–274.
- Chiavenato, I. (2020). *Administración: teoría, proceso y práctica*. Ciudad de México, México: McGraw-Hill.
- Earnest, A. (2005). Using autoregressive integrated moving average (ARIMA) models to predict and monitor the number of beds occupied during a SARS outbreak in a tertiary hospital in Singapore. *BMC Health Services Research*, 36.
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice*. OTexts.
- Lee, A. H., Lympelopoulou, P., Cohen, J. T., Wong, J. B., & Hughes, M. C. (2021). *Forecasting COVID-19 counts at a single hospital: A hierarchical Bayesian approach*. arXiv.
- Organización Mundial de la Salud. (2023). *Indicadores esenciales de servicios hospitalarios*. OMS.
- Palmer, J., Lakhiani, A., Brett, S. J., & Ercole, A. (2024). Feasibility of forecasting future critical care bed availability using data-driven computational forecast modelling. *BMJ Open Respiratory Research*, e002237.
- Phillip, J., Mullner, R., & Andes, S. (1984). Hospital occupancy: Measurement and implications. *National Library of Medicine Journal*, 112–119.

- Schiele, J., Koperina, T., & Brunner, J. O. (2020). Predicting intensive care unit bed occupancy for integrated operating room scheduling via neural networks. *Naval Research Logistics*, 319–336.
- Scott, S. L., & Varian, H. R. (2015). Predicting the present with Bayesian structural time series. *International Journal of Mathematical Modelling and Numerical Optimisation*, 4–23.
- Seo, H., Kim, M., & Park, S. (2024). Forecasting hospital room and ward occupancy using reinforcement learning. *Applied Soft Computing Journal*, 110053.
- Shmueli, G. (2010). To explain or to predict? *Statistical Science*, 289–310.
- Zhang, F., Li, X., & Liu, Y. (2024). Comparison of ARIMA and Bayesian Structural Time Series in dynamically predicting epidemiological trends: Evidence from Jiangsu Province, China. *Journal of Medical Systems*, 215–228.