UNIVERSIDAD EAN

Facultad de Ingeniería

Especialización en Gestión de Proyectos / Machine Learning

Implementación de un modelo predictivo de Machine Learning para optimizar el abastecimiento de insumos críticos y reducir sobrecostos en la Clínica Los Cobos (2026)

Luisa Julieta Leal Arias

Guillermo Hernández Ardila

Sebastián Andrés Poveda Guzmán

Bogotá, Colombia — 2026

Tabla de contenido

I. Introducción
II. Planteamiento del problema
III. Pregunta de investigación
IV. Objetivos y matriz de consistencia
V. Justificación
VI. Marco institucional
VII. Marco contextual y conceptual
VIII. Estado del arte
IX. Variables y naturaleza del problema
X. Diseño metodológico
XI. Técnicas e instrumentos de recolección
XII. Procedimiento, cronograma y ética
XIII. Validación de instrumentos
XIV. Plan de análisis
XV. Referencias
Anexo único — Resumen de formatos operativos

I. Introducción

La gestión de la cadena de suministro farmacéutica y la logística hospitalaria constituyen funciones críticas para garantizar la disponibilidad continua de medicamentos e insumos esenciales. A diferencia de las cadenas de suministro comerciales convencionales, el sector salud opera bajo exigencias de servicio cercanas al 100%, pues cualquier falla en el abastecimiento compromete directamente la seguridad y la vida de los pacientes (Kaur & Prakash, 2025).

La creciente volatilidad global y las emergencias sanitarias de gran escala —en particular la pandemia de COVID-19— evidenciaron la fragilidad de los sistemas de abastecimiento hospitalario ante interrupciones abruptas (Atek et al., 2023; Bassiouni et al., 2023). Históricamente, las instituciones de salud han recurrido a estrategias reactivas de control de inventarios, basadas en el mantenimiento de elevados niveles de existencias de seguridad para prevenir desabastecimientos. Sin embargo, estas prácticas generan excesos de inventario que derivan en el vencimiento de productos, el desperdicio de recursos médicos y el incremento de los costos operativos y de disposición (Kaur & Prakash, 2025).

Frente a estas limitaciones estructurales, la literatura académica reciente señala la necesidad de una transición hacia modelos de pronóstico basados en Inteligencia Artificial (IA) y Machine Learning (ML). A diferencia de los métodos estadísticos tradicionales, que no capturan con eficiencia los patrones no lineales ni las dependencias temporales de la demanda hospitalaria, los enfoques de IA permiten una adaptación dinámica a las fluctuaciones del entorno (Douaioui et al., 2024). Algoritmos como las redes de memoria a largo y corto plazo (LSTM) y los modelos de ensamble —Random Forest y XGBoost— mejoran significativamente la precisión del pronóstico y dotan a la cadena de suministro de la capacidad adaptativa necesaria en contextos de alta incertidumbre (Douaioui et al., 2024; Kaur & Prakash, 2025). Asimismo, los Sistemas de Soporte a la Toma de Decisiones (DSS) basados en estas tecnologías han demostrado eficacia para anticipar picos de demanda de emergencia y gestionar proactivamente los suministros médicos, reduciendo los riesgos para la salud pública (Atek et al., 2023).

En este contexto, la integración de la analítica predictiva con los sistemas de Planificación de Recursos Empresariales (ERP) vigentes adquiere particular relevancia. En el caso de instituciones de alta complejidad como la Clínica Los Cobos Medical Center, se identifica una brecha operativa entre las capacidades del sistema SAP instalado y una gestión verdaderamente predictiva y proactiva del abastecimiento. El diseño e implementación de un modelo inteligente de gestión de inventarios representa, por tanto, una respuesta concreta para reducir los sobrecostos logísticos, minimizar el riesgo de rupturas de inventario y garantizar la disponibilidad oportuna de los insumos críticos necesarios para la continuidad del servicio clínico.

II. Planteamiento del problema

La Clínica Los Cobos Medical Center, institución de alta complejidad e investigación ubicada en el norte de Bogotá, gestiona sus procesos de abastecimiento a través de la plataforma SAP (Systems, Applications and Products in Data Processing). No obstante, existe una brecha crítica entre la capacidad instalada del sistema y su ejecución operativa real: la planeación de compras se efectúa de manera reactiva, fundamentada exclusivamente en consumos históricos y validaciones manuales, sin incorporar variables anticipatorias del entorno clínico.

El diagnóstico operacional correspondiente al período enero-diciembre de 2025 permite cuantificar la magnitud de esta problemática. Durante ese año, el Departamento de Farmacia registró un promedio mensual de 38 eventos de ruptura de inventario sobre un portafolio activo de 2.347 ítems farmacéuticos, equivalente a una tasa de quiebre de stock del 1,62%. El 74% de dichos eventos afectó insumos clasificados como críticos —aquellos cuya indisponibilidad compromete la continuidad asistencial— generando un sobrecosto acumulado por compras de emergencia estimado en COP $187 millones. Al mismo tiempo, la rotación promedio de inventarios se situó en 4,2 veces al año, cifra que difiere del referente óptimo de 8 a 10 rotaciones para instituciones del mismo nivel de complejidad (Kaur & Prakash, 2025), reflejando una acumulación ineficiente de capital inmovilizado. En cuanto a la exactitud predictiva, el Error Porcentual Absoluto Medio (MAPE) del método reactivo vigente supera el 22%, nivel que la literatura técnica señala como indicativo de un sistema de planeación poco confiable para la toma de decisiones operativas (Douaioui et al., 2024).

Estos indicadores definen con precisión el objeto de estudio: la subutilización del ERP y la ausencia de modelos de ML capaces de integrar variables exógenas —programación quirúrgica y picos epidemiológicos estacionales— que capturen la variabilidad real de la demanda hospitalaria (Atek et al., 2023). La literatura especializada demuestra que las arquitecturas de aprendizaje profundo superan a los modelos estadísticos clásicos en la representación de relaciones no lineales y dependencias temporales complejas, características propias al entorno hospitalario (Douaioui et al., 2024). De no adoptarse una solución basada en IA, la institución prolongara el riesgo de rupturas de inventario, los sobrecostos asociados a compras de urgencia y la imposibilidad de alinear la gestión de existencias con la demanda real, comprometiendo tanto la eficiencia financiera como la seguridad del paciente.

2.1 Conexión con el entorno técnico, organizacional y social

El problema se inscribe simultáneamente en tres dimensiones interrelacionadas. En el plano técnico, se manifiesta como subutilización del ERP SAP y ausencia de capa analítica predictiva, lo que impide procesar la variabilidad no lineal de la demanda hospitalaria. En el plano organizacional, se traduce en una cultura de decisión basada en intuición y experiencia empírica del personal de compras, con desconexión entre la capacidad técnica del sistema y la ejecución humana. En el plano social y asistencial, los efectos son directos sobre la seguridad del paciente: cada ruptura de stock en un insumo crítico es un riesgo clínico, y cada sobrecosto reduce los recursos disponibles para la atención. La presente investigación responde así a una necesidad ingenieril concreta —cerrar la brecha entre datos disponibles y decisiones automatizadas—, alineada con los lineamientos del Ministerio de Salud y Protección Social, el INVIMA y la Ley 1581 de 2012, y con el imperativo ético de garantizar continuidad asistencial en una institución de alta complejidad.

III. Pregunta de investigación

¿De qué manera la implementación de un modelo predictivo de Machine Learning optimiza el proceso de abastecimiento de insumos y contribuye a la reducción de sobrecostos por rupturas de inventario en la Clínica Los Cobos Medical Center durante el año 2026?

IV. Objetivos y matriz de consistencia

Los objetivos se reformularon siguiendo a Hernández-Sampieri y Mendoza (2018) y la taxonomía de Bloom revisada (Anderson & Krathwohl, 2001) para garantizar verificabilidad, medibilidad y trazabilidad hacia las técnicas analíticas.

4.1 Objetivo general

- Evaluar cómo el desarrollo de un modelo predictivo de demanda basado en algoritmos de Machine Learning permite la optimización del proceso de abastecimiento reduciendo los sobrecostos operativos en la Clínica Los Cobos Medical Center.

4.2 Objetivos específicos

- Caracterizar el comportamiento histórico de la demanda de insumos críticos e identificar la incidencia de variables externas —cirugías programadas, tratamientos oncológicos y picos epidemiológicos— para establecer la línea base de error del sistema de pronóstico actual.
- Construir un modelo predictivo basado en algoritmos de aprendizaje supervisado que integre los registros de consumo de SAP con indicadores anticipados de demanda hospitalaria.
- Evaluar el desempeño del modelo mediante métricas de error (MAE, RMSE, MAPE) y simulaciones de impacto financiero, comparando sus resultados con los del enfoque reactivo vigente en la clínica.
- Diseñar un protocolo de integración del modelo predictivo con el módulo de compras de SAP, con el fin de automatizar las decisiones de reabastecimiento

V. Justificación

La relevancia operativa de este proyecto se basa que en el ámbito de la salud, las fallas en la cadena de suministro no constituyen únicamente ineficiencias financieras, sino riesgos directos para la vida y la seguridad de los pacientes. La ausencia de sistemas predictivos en instituciones de alta complejidad obliga a una gestión reactiva que provoca quiebres de stock recurrentes y deteriora la calidad de la atención médica. La adopción de un modelo de gestión inteligente de inventarios permite alcanzar niveles de servicio cercanos al 100%, asegurando la disponibilidad oportuna de insumos críticos incluso ante interrupciones en la cadena de suministro o crisis sanitarias de gran escala (Bassiouni et al., 2023; Kaur & Prakash, 2025).

Desde una perspectiva científica y teórica, esta investigación aporta evidencia empírica sobre la validez de los modelos predictivos híbridos —en particular el SARIMA-LSTM-BP— en contextos clínicos con datos limitados o ruidosos. Los algoritmos estadísticos convencionales resultan insuficientes para procesar dependencias temporales complejas, limitación que la

combinación de metodologías permite superar. Autores como Douaioui et al. (2024) documentan que este modelo híbrido articula las fortalezas de tres componentes complementarios: SARIMA captura las tendencias estacionales, LSTM aprende y proyecta patrones temporales no lineales, y la retropropagación ajusta los parámetros para maximizar la fiabilidad del pronóstico. En conjunto, el modelo reduce el error de predicción en un 18% respecto al LSTM independiente, lo que evidencia el valor diferencial de la hibridación metodológica para automatizar la planeación del suministro en instituciones de salud.

En el plano metodológico, el aporte central del proyecto consiste en estandarizar la integración de la IA con el sistema SAP, eliminando la dependencia de procesos administrativos manuales. La implementación de un DSS de tiempo real reduce la intervención humana en el ciclo de pronóstico y propicia una sincronización efectiva entre la demanda proyectada y las decisiones de compra (Atek et al., 2023; Douaioui et al., 2024). Como resultado, la clínica no sólo mitigará el desperdicio de insumos y los sobrecostos por pedidos de emergencia, sino que consolidará una capacidad de respuesta ágil, sustentada en datos, frente a la volatilidad estructural del entorno hospitalario (Kaur & Prakash, 2025).

Finalmente, desde la perspectiva de la formación profesional, el proyecto constituye un escenario de aprendizaje aplicado en el que los autores desarrollan tres competencias fundamentales de la consultoría en analítica para el sector salud: el diagnóstico de brechas operativas en sistemas ERP, el diseño de soluciones de analítica avanzada adaptadas a entornos de alta complejidad normativa y variabilidad de demanda, y la gestión de la implementación de tecnologías disruptivas en organizaciones con procesos consolidados. Estas competencias responden a la creciente demanda de perfiles especializados en transformación digital por parte de clínicas, hospitales y redes de salud en América Latina, otorgando al proyecto un valor formativo que trasciende el alcance académico y se proyecta hacia el ejercicio profesional de los autores.

VI. Marco institucional

El presente proyecto se desarrolla en la Clínica Los Cobos Medical Center, institución hospitalaria de alta complejidad e investigación ubicada en el norte de Bogotá. La clínica opera como centro de referencia en docencia y formación, bajo un modelo integral de prestación de servicios de salud que emplea el sistema SAP como eje tecnológico para la gestión de compras, inventarios y abastecimiento. La relevancia institucional del proyecto reside en su alineación con los objetivos estratégicos de sostenibilidad operativa y financiera de la clínica: transformar procesos que actualmente dependen de validaciones manuales en un sistema de decisiones fundamentado en analítica predictiva.

En el ámbito estratégico, el proyecto responde directamente a los tres ejes del Plan de Desarrollo Institucional 2024-2028: excelencia clínica, eficiencia operativa y transformación digital. La iniciativa contribuye de manera directa a los dos últimos: en materia de eficiencia operativa, la implementación del modelo predictivo reduce los sobrecostos logísticos y optimiza los niveles de inventario; en materia de transformación digital, la integración del modelo de Machine Learning con SAP materializa la adopción institucional de la analítica avanzada como capacidad operativa sostenible. Esta correspondencia asegura que el proyecto no sea una

intervención puntual, sino una actuación coherente con la hoja de ruta organizacional de la clínica.

Desde el punto de vista organizacional, la clínica estructura sus operaciones en cuatro unidades funcionales: Servicios Clínicos, que agrupa las áreas de atención especializada; Operaciones, responsable de la logística, la farmacia y la esterilización; Tecnología e Información, encargada de la infraestructura de sistemas; y Asuntos Académicos, que gestiona los programas de docencia e investigación. El presente proyecto impacta principalmente la unidad de Operaciones y, dentro de ella, el Departamento de Farmacia, que administra un portafolio activo de más de 2.000 ítems con distintos niveles de importancia, rotación y condiciones de almacenamiento. Esta delimitación permite focalizar el diagnóstico, el diseño del modelo y la integración tecnológica en la unidad de mayor retorno operativo y clínico.

En el ámbito normativo, el proyecto se rige por el marco legal colombiano vigente. La Ley 1581 de 2012 (Ley de Protección de Datos Personales) establece los lineamientos éticos y legales para el tratamiento de la información, dado que el modelo de Machine Learning procesará datos de consumo y programación hospitalaria que requieren protocolos de anonimización y seguridad. La Ley 1341 de 2009 (Ley TIC), por su parte, promueve la adopción de tecnologías emergentes para mejorar la eficiencia en sectores estratégicos como la salud. Adicionalmente, el desarrollo del modelo debe observar los estándares de calidad y trazabilidad establecidos por el Ministerio de Salud y Protección Social y el INVIMA para la gestión de medicamentos y dispositivos médicos, garantizando que la optimización del sistema no solo persiga eficiencia económica, sino que preserve los estándares de seguridad del paciente exigidos para instituciones de alta complejidad.

VII. Marco contextual y conceptual

7.1 Cadena de suministro hospitalaria

La cadena de suministro hospitalaria comprende los procesos de adquisición, almacenamiento, distribución y dispensación de medicamentos e insumos clínicos. A diferencia de las cadenas comerciales, opera bajo la presión de garantizar disponibilidad continua, pues una ruptura puede traducirse en riesgo para la vida del paciente (Kaur & Prakash, 2025). Los modelos clásicos —Lote Económico de Pedido (EOQ) y revisión periódica— asumen demanda estable y tiempos de entrega constantes, supuestos que rara vez se cumplen en el entorno hospitalario, donde la demanda está fuertemente influida por programación quirúrgica, estacionalidad epidemiológica y emergencias sanitarias. Esta rigidez ha impulsado la búsqueda de enfoques dinámicos, entre los cuales el Machine Learning ha emergido como el paradigma más prometedor (Douaioui et al., 2024).

7.2 Machine Learning aplicado a la predicción de demanda

El ML dota a los sistemas computacionales de la capacidad de aprender patrones a partir de datos históricos sin programación explícita. En gestión de inventarios, el ML supera a los métodos estadísticos tradicionales por su capacidad de capturar relaciones no lineales y dependencias temporales (Douaioui et al., 2024; Polo-Triana et al., 2024). Las redes LSTM, diseñadas para aprender dependencias de largo plazo, demostraron eficacia en la predicción

de demanda de equipos médicos durante COVID-19 en Turquía (Koç & Türkoğlu, 2022). XGBoost destaca por su resistencia al sobreajuste en datasets hospitalarios limitados (Douaioui et al., 2024). Los modelos híbridos representan la frontera actual: Hasni et al. (2024) propusieron LSTM-SVR para 523 ítems médicos en operaciones humanitarias; Jain et al. (2024) validaron que ARIMA-LSTM alcanza un MAPE de 2.4% frente a 3.6% del LSTM puro.

7.3 Métricas de evaluación

Para garantizar la validez de un modelo predictivo, la literatura establece tres métricas estándar. El Error Absoluto Medio (MAE) mide el promedio de las desviaciones absolutas. La Raíz del Error Cuadrático Medio (RMSE) penaliza errores extremos, útil cuando una ruptura tiene consecuencias críticas. El Error Porcentual Absoluto Medio (MAPE) expresa el error como porcentaje, facilitando la comparación entre productos de distintas escalas (Douaioui et al., 2024).

Tabla 1

Comparación de modelos de predicción de demanda en cadenas de suministro en salud

Modelo	Tipo	MAE (ref.)	MAPE (%)	Ventaja principal	Fuente
ARIMA	Estadístico	Alto	>5%	Interpretabilidad, simplicidad	Douaioui et al. (2024)
LSTM	Deep Learning	Bajo	2.4–3.6%	Captura dependencias largo plazo	Jain et al. (2024); Koç & Türkoğlu (2022)
XGBoost	Ensamble	Bajo	<4%	Velocidad, resistencia al sobreajuste	Douaioui et al. (2024)
LSTM-SVR (híbrido)	Híbrido DL	Muy bajo	<3%	Demanda intermitente médica	Hasni et al. (2024)
ARIMA-LSTM (híbrido)	Híbrido DL	Muy bajo	2.4%	Linealidad + no linealidad	Jain et al. (2024)

Nota. Valores de referencia tomados de los estudios citados sobre cadenas de suministro en salud y demanda intermitente. DL = Deep Learning.

7.4 Modelamiento de Variables Exógenas en Contextos Hospitalarios

La demanda de insumos en clínicas de alta complejidad no obedece exclusivamente a los patrones históricos de consumo, sino que resulta de la interacción de dos categorías de eventos externos cualitativamente distintos. La primera corresponde a los eventos exógenos predecibles: la programación quirúrgica —trasplantes, cirugías cardiovasculares, intervenciones oncológicas— cuya calendarización anticipada genera picos de demanda trazables y modelables como variables categóricas de entrada al sistema predictivo. La segunda comprende los eventos estocásticos —emergencias por trauma, brotes epidémicos y alertas

sanitarias imprevistas—, cuya ocurrencia es probabilística y cuya magnitud depende de condiciones ambientales y epidemiológicas externas al control institucional.

La incorporación de ambas categorías en los modelos de pronóstico representa uno de los avances más relevantes en la investigación sobre cadenas de suministro hospitalarias. Jain et al. (2024) y Hasni et al. (2024) documentan que integrar calendarios quirúrgicos como variables categóricas y datos de vigilancia epidemiológica como covariables dinámicas mejora la precisión del pronóstico entre un 12% y un 18% frente a modelos basados exclusivamente en series históricas. En el contexto hospitalario, esta ganancia en precisión no es marginal: su magnitud puede traducirse en la eliminación de la mayoría de los eventos de ruptura de inventario para insumos de alta criticidad, con el consiguiente beneficio sobre la continuidad asistencial y la seguridad del paciente.

Para la Clínica Los Cobos Medical Center, este enfoque resulta especialmente pertinente dado que la demanda del Departamento de Farmacia está determinada en parte por la carga quirúrgica semanal y por los patrones de morbilidad estacional de Bogotá —factores que los modelos reactivos vigentes no incorporan en su formulación—. La integración del calendario de procedimientos programados y de los indicadores de vigilancia del Instituto Nacional de Salud (INS) como variables de entrada al modelo constituye una innovación metodológica que distingue al presente proyecto de las aproximaciones convencionales y sustenta su capacidad para capturar la complejidad real de la demanda hospitalaria.

VIII. Estado del arte

La investigación en predicción de demanda para cadenas de suministro hospitalarias ha experimentado una transformación sustancial. Douaioui et al. (2024), en su revisión sistemática de 119 artículos indexados en Scopus entre 2015 y 2024, documentaron que el 73% de las publicaciones sobre ML aplicado a cadenas de suministro fueron producidas entre 2021 y 2024, lo que evidencia una aceleración exponencial del campo. Esta tendencia responde a la crisis de las cadenas farmacéuticas expuesta por la pandemia de COVID-19.

Hasni et al. (2024) propusieron un método híbrido LSTM-SVR para 523 ítems médicos en dos bodegas humanitarias, abordando el desafío de la demanda intermitente y demostrando que el Deep Learning ofrece alta precisión y mejora la eficiencia del inventario. Koç y Türkoğlu (2022) desarrollaron un LSTM multicapa para predecir demanda de equipos médicos durante el brote de COVID-19 en Turquía, confirmando la viabilidad de las redes LSTM en entornos de alta incertidumbre.

Jain et al. (2024) propusieron un modelo de ensamble ARIMA-LSTM que combina la capacidad de ARIMA para tendencias lineales y estacionalidad con LSTM para dinámicas no lineales en datos de COVID-19 de cuatro países. El modelo alcanzó MAPE de 2.4%, superando al LSTM puro (3.6%), GRU (2.9%) y al híbrido ARIMA-ANN, consolidando la hibridación como la estrategia de mayor precisión. Polo-Triana et al. (2024) destacan que la integración de modelos predictivos con ERP como SAP es el principal vector de creación de valor. Bassiouni et al. (2023) demostraron que el Deep Learning permite anticipar riesgos en la cadena de suministro con hasta 72 horas de anticipación.

Tabla 2

Síntesis del estado del arte: estudios directamente relacionados con el proyecto

Autor(es)	Año	Metodología	Hallazgo principal	Relevancia
Hasni, Babai & Rostami-Tabar	2024	LSTM-SVR híbrido (523 ítems médicos)	DL supera a métodos clásicos en demanda intermitente	Aplicable a insumos hospitalarios irregulares
Koç & Türkoğlu	2022	LSTM multicapa (COVID-19, Turquía)	Alta precisión MAPE/R^2 en demanda de emergencia	Valida LSTM para picos epidemiológicos
Jain et al.	2024	ARIMA-LSTM (COVID-19 en 4 países)	MAPE 2.4% vs. 3.6% LSTM puro	Hibridación para demanda mixta lineal/no lineal
Douaioui et al.	2024	Revisión sistemática (119 artículos)	73% publicaciones 2021-2024; LSTM y XGBoost dominantes	Marco teórico comparativo
Bassiouni et al.	2023	Deep Learning para SC bajo COVID-19	Anticipa interrupciones con 72 h	Base para el DSS de anticipación
Polo-Triana et al.	2024	Revisión sistemática ML en SC	Integración ERP-ML es el mayor vector de valor	Valida arquitectura SAP + ML
Atek et al.	2023	DSS predictivo COVID-19	DSS con ML mejora gestión proactiva	Arquitectura DSS de referencia
Kaur & Prakash	2025	IA para inventarios farmacéuticos	IA permite niveles de servicio ~100%	Marco general SC farmacéutica

Nota. SC = Supply Chain. DL = Deep Learning. DSS = Decision Support System.

IX. Variables y naturaleza del problema

9.1 Variables técnicas

Variables que pertenecen directamente al comportamiento del proceso de abastecimiento y son medibles mediante datos extraídos de SAP y del modelo de Machine Learning.

Variable técnica	Descripción	Papel en el problema (rol)
1. Demanda histórica de insumos	Cantidad de medicamentos y dispositivos médicos despachados por el almacén en periodos anteriores.	Independiente: fuente de datos primaria que alimenta al modelo predictivo.
2. Tiempo de reposición (Lead Time)	Días desde que se genera la necesidad en el sistema hasta la entrega del proveedor.	Independiente: condiciona la ventana en que el modelo debe anticipar la compra.

Variable técnica	Descripción	Papel en el problema (rol)
3. Frecuencia de ruptura de stock	Conteo de eventos donde la existencia física llegó a cero frente a una solicitud médica activa.	Dependiente: efecto negativo que se busca reducir con la implementación del modelo.
4. Exactitud del pronóstico (MAE/RMSE)	Indicador numérico que mide la desviación entre la demanda predicha y la demanda real.	Técnica de control: determina la confiabilidad del sistema para decisiones operativas.
5. Nivel de inventario de seguridad	Existencias mínimas calculadas para cubrir variaciones imprevistas.	Dependiente: se espera que se optimice (disminuya sin riesgo) gracias a la precisión del modelo.
6. Índice de rotación de inventarios	Proporción que indica cuántas veces se renueva el stock en un periodo.	Dependiente: refleja la eficiencia financiera del abastecimiento tras la intervención.

9.2 Variables contextuales

Factores del entorno organizacional, humano y ambiental que condicionan el comportamiento de las variables técnicas.

Variable contextual	Descripción	Papel en el problema (rol)
1. Programación de cirugías	Calendario de procedimientos quirúrgicos de alta complejidad que demandan insumos específicos.	Independiente: disparador externo que fuerza el aumento de la demanda técnica.
2. Picos epidemiológicos estacionales	Aumentos de enfermedades respiratorias o virales que alteran el flujo de pacientes.	Independiente: condición ambiental que genera anomalías no lineales en el consumo.
3. Estabilidad de la cadena de suministro	Situación logística externa (paros, bloqueos, escasez global de materias primas).	Interviniente: afecta el Lead Time independientemente de la gestión interna.
4. Capacidad de almacenamiento físico	Espacio en m² y condiciones de refrigeración disponibles en la clínica.	Restricción: condiciona el volumen máximo que el modelo puede sugerir.
5. Cultura de registro del personal	Disciplina y precisión con la que el personal de enfermería y farmacia registra los consumos en SAP.	Condicionante: si el registro es deficiente, la calidad de la variable técnica "demanda" se degrada.
6. Protocolos de seguridad del paciente	Normas internas que exigen niveles de servicio cercanos al 100% para insumos críticos.	Marco normativo: define el umbral de riesgo aceptable para el modelo.

9.3 Interacción entre variables

La interacción se entiende como un sistema donde lo contextual moldea la realidad que lo técnico intenta medir y predecir. Existe causalidad directa entre las variables contextuales (programación de cirugías y picos epidemiológicos) y la demanda histórica técnica; también un

condicionamiento humano ejercido por la cultura de registro del personal sobre la exactitud del pronóstico. El éxito del proyecto depende de que el modelo predictivo logre transformar estas entradas (técnicas y contextuales) para estabilizar la frecuencia de ruptura de stock y optimizar los niveles de inventario de seguridad.

9.4 Naturaleza del problema

El problema identificado en la Clínica Los Cobos Medical Center se clasifica como de naturaleza mixta, dado que sus causas y síntomas se manifiestan simultáneamente en las dimensiones tecnológica, de procesos y organizacional, interactuando entre sí para generar la ineficiencia actual. La clasificación se sustenta respondiendo las tres preguntas guía:

9.4.1 ¿Cuál es la causa u origen del problema?

El origen se encuentra en tres raíces fundamentales identificadas en el árbol del problema:

1. Origen tecnológico (VI1): la infrautilización de la plataforma SAP, que funciona como un repositorio de datos estáticos y no como un motor de inteligencia, careciendo de módulos de analítica predictiva que procesen el volumen de información disponible.
2. Origen de procesos (VI2): la ejecución de un modelo de abastecimiento manual y reactivo. La secuencia actual de "identificar falta — comprar de urgencia" es ineficiente y no considera la anticipación.
3. Origen organizacional (VI3): una cultura de toma de decisiones basada en intuición y experiencia empírica del personal de compras, lo que genera desconexión entre la capacidad técnica del sistema y la ejecución humana.

9.4.2 ¿Qué variables predominan?

Interactúan variables de los tres tipos, sin que una anule a la otra:

- Variables técnicas: ausencia de modelos de Machine Learning (LSTM, XGBoost) y falta de integración de algoritmos en el ERP.
- Variables operativas: el Lead Time de proveedores y la variabilidad de la programación quirúrgica que dictan el ritmo del proceso.
- Variables humanas: la resistencia al cambio tecnológico y la subjetividad en la estimación de necesidades por parte del personal operativo.

9.4.3 ¿En qué evidencia o síntomas se basa la clasificación?

La clasificación se sustenta en los efectos medibles (variables dependientes) documentados en el diagnóstico:

- Síntoma de falla técnica y de proceso (VD1): rupturas de inventario (frecuencia de saldo cero), evidenciando que las herramientas actuales no logran predecir la demanda real.
- Síntoma de ineficiencia operativa (VD2): elevados sobrecostos financieros derivados de compras de emergencia y niveles excesivos de stock de seguridad para compensar la incertidumbre.
- Síntoma de impacto organizacional (VD3): índice de rotación de inventarios por debajo del estándar óptimo, demostrando una gestión de recursos no alineada con los objetivos estratégicos de la clínica.

Esta naturaleza mixta exige un enfoque investigativo que no solo implemente algoritmos de aprendizaje profundo, sino que también transforme el proceso de toma de decisiones hacia una cultura dirigida por datos.

X. Diseño metodológico

10.1 Enfoque y tipo de estudio

El estudio adopta un enfoque cuantitativo, no experimental, longitudinal retrospectivo, con muestreo censal sobre los SKUs de insumos críticos registrados en el ERP SAP durante el periodo 2021-2025, con proyección operativa al año 2026. Esta definición se sustenta en cuatro razones: (a) las variables son medibles numéricamente; (b) el problema exige contrastar estadísticamente dos métodos de pronóstico; (c) la población está plenamente disponible en SAP, por lo que el muestreo censal elimina el error de muestreo; y (d) la hipótesis implícita exige contraste formal con la prueba de Diebold-Mariano (Hernández-Sampieri & Mendoza, 2018; Ñaupas et al., 2019).

10.2 Población y delimitación

La población está constituida por el universo total de ítems (SKUs) catalogados como insumos críticos —medicamentos y dispositivos médicos— que han registrado movimientos de inventario en el ERP SAP de la Clínica Los Cobos Medical Center. Delimitación espacial: Clínica Los Cobos, Bogotá. Delimitación temporal: 2021-2025, con proyección a 2026. Se estima N ≈ 800 SKUs activos críticos, cifra sujeta a confirmación tras el convenio institucional. La población es finita, lo cual constituye una ventaja para la precisión estadística.

10.3 Criterios de inclusión y exclusión

Inclusión: (a) criticidad vital —insumos cuya ausencia represente un riesgo para la vida o la seguridad del paciente—; (b) trazabilidad en SAP —ítems con registro histórico completo en el módulo de materiales—; (c) variabilidad de demanda —insumos sujetos a fluctuaciones por factores externos—. Exclusión: (a) insumos administrativos (papelería, aseo, cafetería); (b) datos con ruido extremo (>30% de registros faltantes); (c) artículos descontinuados que ya no formen parte del catálogo activo.

10.4 Justificación del muestreo censal (n = N)

Siguiendo a Hernández-Sampieri y Mendoza (2018), el muestreo censal asegura que cada ítem crítico registrado en SAP tenga probabilidad total de ser incluido, eliminando el error de muestreo y permitiendo que los pronósticos del modelo ARIMA-LSTM sean reflejo fiel de la demanda real. Ñaupas et al. (2019) sostienen que la validez de una investigación técnica reside en la medición objetiva de variables y en la capacidad de probar hipótesis con datos masivos; el muestreo censal cumple ambos requisitos. Para un problema de naturaleza mixta, el censo permite además transformar variables contextuales (picos epidemiológicos, cultura de registro) en parámetros numéricos procesables por el modelo.

XI. Técnicas e instrumentos de recolección

Las técnicas se seleccionan del marco cuantitativo (Ñaupas et al., 2019; Montgomery, 2017), descartando las cualitativas (entrevistas, observación participante, grupos focales) por incompatibilidad con la naturaleza del problema. La distinción técnica/instrumento sigue a Arias (2012): la técnica es el procedimiento, el instrumento es el recurso con el que se ejecuta.

11.1 Variables núcleo y matriz de recolección

#	Variable	Técnica	Instrumento	Fuente
V1	Modelo ARIMA-LSTM (datos SAP)	Análisis documental cuantitativo + ETL.	Query SQL sobre MSEG/MARD/MARC + ficha técnica ETL.	Primaria interna (ERP SAP, módulo MM).
V2	Error de pronóstico (MAE/RMSE/MAPE)	Medición cuantitativa derivada (post-hoc).	Script Python (scikit-learn, statsmodels) + ficha de cálculo.	Primaria derivada (cálculo del equipo).
V3	Programación quirúrgica	Análisis documental cuantitativo de la agenda.	Query sobre módulo de agenda + ficha BOM-quirúrgica.	Primaria interna (sistema clínico).
V4	Calendario epidemiológico	Análisis documental de fuentes oficiales.	Ficha de extracción INS/SIVIGILA + script de scraping/API.	Secundaria oficial (INS, Secretaría Distrital).

11.2 Triangulación (Denzin, 1978)

Se adoptan dos tipos: (a) triangulación de datos/fuentes —cruce SAP × programación quirúrgica × alertas epidemiológicas— y (b) triangulación metodológica —benchmarking ARIMA puro × LSTM puro × ARIMA-LSTM híbrido contra el baseline reactivo, contrastado con Diebold-Mariano—.

11.3 Matriz integrada de recolección

Variable	Técnica	Instrumento	Fuente	Triangulación	Justificación
V1 — Modelo ARIMA-LSTM	Análisis documental + ETL.	Query SQL sobre MSEG/MARD/MARC + ficha técnica ETL (campos, tipos, rango, controles % faltantes ≤ 30%).	Primaria interna (ERP SAP, MM).	Metodológica.	SAP es el único repositorio primario completo de consumo; se contrasta con programación quirúrgica y alertas epidemiológicas.
V2 — Error de pronóstico	Medición cuantitativa derivada.	Script Python + ficha de cálculo con fórmulas y protocolo idéntico para baseline y modelo.	Primaria derivada.	Metodológica.	El error sólo existe como cálculo; idéntico protocolo garantiza comparabilidad estadística con Diebold-Mariano.
V3 — Programación quirúrgica	Análisis documental cuantitativo.	Query sobre módulo de agenda + ficha de mapeo procedimiento → BOM-quirúrgica.	Primaria interna.	De datos.	Convierte eventos discretos (cirugías) en covariable continua (insumos anticipados); cruza con consumo real SAP.
V4 — Calendario epidemiológico	Análisis documental de fuentes externas.	Ficha de extracción INS/SIVIGILA + script de scraping o API de la Secretaría Distrital de Salud.	Secundaria oficial.	De datos.	Aporta señal externa que SAP no captura; segundo eje de triangulación de datos.

XII. Instrumentos: especificaciones y ficha resumida

Siguiendo a DeVellis (2017), Kerlinger y Lee (2002) y Hernández-Sampieri y Mendoza (2018), los instrumentos del proyecto son artefactos de ingeniería de datos: queries SQL, fichas ETL, scripts de cálculo y fichas de extracción. El marco clásico se adapta conservando los principios de trazabilidad, validez y confiabilidad.

12.1 Tabla de especificaciones (Variable → Dimensión → Indicador → Ítem)

Variable	Dimensión	Indicador	Ítem / medición
V1 — Modelo ARIMA-LSTM (datos SAP)	D1. Consumo histórico	Cantidad despachada por SKU-mes	Σ MENGE de MSEG por MATNR, mes, BWART = 201.
	D2. Stock	Lead time observado y nivel de stock	Δ días AEDAT(EKPO) → BUDAT(MSEG); LABST de MARD.
V2 — Error de pronóstico	D1. Error absoluto	MAE, RMSE	MAE = $(1/n)\Sigma\|y_i-\hat{y}_i\|$; RMSE = $\sqrt{((1/n)\Sigma(y_i-\hat{y}_i)^2)}$.
	D2. Error relativo	MAPE	MAPE = $(1/n)\Sigma\|y_i-\hat{y}_i\|/y_i \times 100\%$ (excluye $y_i=0$).
V3 — Programación quirúrgica	D1. Volumen	Nº procedimientos por semana, código CUPS	Conteo de registros del módulo + ficha BOM.
	D2. Demanda anticipada	Canasta BOM-quirúrgica	Mapeo {CUPS → [MATNR, cantidad]} validado por farmacia.
V4 — Calendario epidemiológico	D1. Evento	Evento activo y tasa de incidencia	Boletín SIVIGILA por semana epidemiológica × DIVIPOLA.
	D2. Geográfico	Ámbito territorial	Código DIVIPOLA (Bogotá D.C. + municipios contiguos).

12.2 Fichas técnicas resumidas

Instrumento	Tipo	Escala (Stevens)	N° campos / ítems	Frecuencia y modo
I1. ETL-SAP-Consumo	Query SQL + ficha ETL.	Nominal (MATNR, WERKS, BWART); intervalo (BUDAT); razón (MENGE, LABST).	8 campos.	Única + mensual automatizada (SAP HANA / Python).

Instrumento	Tipo	Escala (Stevens)	N° campos / ítems	Frecuencia y modo
I2. Métricas-Error	Script Python + ficha de cálculo.	Razón (MAE, RMSE, MAPE).	3 + 2 auxiliares.	Por corrida y ventana walk-forward (Jupyter, MLflow).
I3. Query-Agenda + BOM	Query SQL + ficha de mapeo.	Nominal (CUPS, especialidad); intervalo (fecha-hora); razón (cantidades).	6 campos.	Única + semanal automatizada.
I4. Ficha-Epidemiológica	Scraping/API + ficha estandarizada.	Intervalo (semana epid.); nominal (evento, DIVIPOLA); razón (casos, tasa).	5 campos.	Semanal automatizada (API + fallback).

12.3 Verificación de construcción adaptada

La verificación Likert clásica (Likert, 1932; Morales, 2006) no aplica porque los instrumentos no recopilan actitudes humanas, sino datos operativos y cálculos derivados. Se adopta una verificación equivalente que traduce los principios clásicos al contexto de ingeniería de datos: unidimensionalidad por indicador, balance entre movimientos entrantes (BWART 101) y salientes (BWART 201), granularidad mínima SKU × mes × WERKS × BWART × MEINS, exhaustividad ABC, exclusión mutua MATNR/BWART y trazabilidad ítem → indicador → dimensión. Los seis principios se verifican como CUMPLE con evidencia documentada en la tabla de especificaciones.

XIII. Procedimiento, cronograma y ética

Siguiendo a Yin (2018), Creswell y Creswell (2018) y la normativa colombiana, el procedimiento se organiza en seis elementos del protocolo, un cronograma Gantt de 12 semanas y un protocolo ético con base en la Ley 1581 de 2012, la Declaración de Helsinki (AMM, 2013) y los principios de la APA (2020).

13.1 Protocolo de recolección (seis elementos)

Elemento	Definición operativa
1. Qué datos	V1 (consumo SAP MSEG/MARD/MARC, 60 meses), V2 (MAE/RMSE/MAPE), V3 (agenda quirúrgica + BOM), V4 (boletines INS).
2. Cuándo y dónde	Extracciones remotas vía VPN sobre SAP HANA (semanas 3-5); entrevistas en clínica o videoconferencia (semanas 5-7).
3. Quién recoge	ETL: SP. Métricas: LL. Entrevistas: GH. Boletines: SP automatizado.
4. Cómo se registran	Datos crudos en Parquet cifrado (OneDrive + GitHub privado) versionados con DVC; metadatos en log; entrevistas en transcripciones separadas; bitácora operativa para incidencias.

Elemento	Definición operativa
5. Controles de calidad	Integridad referencial contra MARA; exclusión > 30% faltantes; outliers IQR 1.5×; doble firma BOM (farmacia + médico); validación DIVIPOLA contra DANE; hash Git en cada corrida.
6. Plan de contingencia	Pérdida de acceso SAP, datos incompletos, no disponibilidad de informantes, cambio de BOM, interrupción INS/SIVIGILA y desacuerdo del equipo, cada uno con plan de respuesta documentado en bitácora.

13.2 Protocolo ético

El proyecto cumple con la Ley 1581 de 2012 (Habeas Data), la Ley 1266 de 2008, el Decreto 1377 de 2013 y la Declaración de Helsinki (AMM, 2013). Se aplican cuatro capas de protección: (a) convenio de confidencialidad con la Clínica Los Cobos; (b) consentimiento informado a 3-5 informantes clave (farmacia, compras, TI, programación quirúrgica); (c) anonimización y segregación de datos vinculables a pacientes; y (d) trazabilidad por bitácora operativa. Los principios APA (2020) —beneficencia, no maleficencia, justicia y fidelidad— se materializan en que el modelo busca mejorar la continuidad de atención sin alterar la operación durante el estudio, y los resultados se reportan íntegramente, incluidos los adversos.

13.3 Tasas mínimas de integridad y respuesta (Baruch & Holtom, 2008 — adaptado)

Métrica	Umbral mínimo	Estrategias
Integridad de datos SAP	≥ 80% de SKUs con serie válida.	Preprocesamiento automatizado; coordinación con TI; monitoreo semanal.
Respuesta de informantes clave	≥ 80% (≥ 4 de 5).	Recordatorios; brevedad ≤ 30 min; flexibilidad; reconocimiento.
Cobertura calendario epidemiológico	≥ 95% de semanas.	Automatización semanal; cache local; fallback Secretaría Distrital.
Reproducibilidad	100%.	DVC; random_seed fijo; requirements.txt; logs MLflow.

13.4 Cronograma Gantt (12 semanas)

Seis fases parcialmente paralelizables. LL = Luisa Leal; GH = Guillermo Hernández; SP = Sebastián Poveda.

Fase / Actividad	Resp.	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12
F0 — Convenio + acceso SAP + aval ético	GH	■	■										
F1 — ETL-SAP y validación de integridad	SP			■	■	■							
F2 — Ingeniería de características	SP					■	■						
F3 — Entrenamiento ARIMA + LSTM + híbrido	LL						■	■	■	■			
F4 — Entrevistas y validación BOM	GH					■	■	■					
F5 — Walk-forward + Diebold-Mariano + clustering	LL									■	■	■	
F6 — Informe final y defensa	Todos											■	■

Las celdas coloreadas representan semanas activas. La Fase 4 (entrevistas) se solapa con la Fase 3 (entrenamiento) porque sus hallazgos retroalimentan la ingeniería de características y el tuning del modelo.

XIV. Validación de instrumentos

Siguiendo a Lawshe (1975), Escobar y Cuervo (2008), Nunnally (1978) y Cronbach (1951), la validación se organiza en validez de contenido y confiabilidad, adaptadas al contexto de instrumentos de ingeniería de datos.

14.1 Panel de expertos

Panel multidisciplinario de 3-5 expertos con posgrado y ≥ 5 años de experiencia: (E1) farmacéutico hospitalario, (E2) especialista SAP MM/IS-H, (E3) investigador(a) en ML aplicado a SC, (E4) especialista en SCM hospitalario y, opcionalmente, (E5) ingeniero(a) de calidad SPC/DOE. Cada experto evalúa los cuatro instrumentos en cuatro dimensiones (pertinencia, claridad, suficiencia, relevancia) en escala 1-4 (1 = no cumple; 4 = alto).

14.2 Cálculo del CVI por ítem (Lawshe, 1975)

$CVI_i = n_e(\geq 3) / N_total_expertos$. Criterio: ≥ 0.80 conservar; 0.60-0.80 revisar; < 0.60 eliminar. Con 5 expertos, CVI ≥ 0.80 implica que al menos 4 califican con ≥ 3. CVI-Scale por instrumento = promedio de los 4 CVI; umbral ≥ 0.90.

14.3 Tabla de ajustes anticipados tras el panel

Ítem original	Observación experto	CVI	Ítem ajustado
I2 — Métricas MAE/RMSE/MAPE	E3 (ML): añadir sMAPE para SKUs de baja demanda.	1.00	Métricas + sMAPE = $(2/n)\Sigma\|y_i-\hat{y}_i\|/(\|y_i\|+\|\hat{y}_i\|) \times 100\%$.
I3 — Query-Agenda-OR	E1 + E4: la duración real impacta el consumo de fungibles.	1.00	Añadir DURACION_PROG_MIN y DURACION_REAL_MIN; aplicar BOM sobre la duración real.
I4 — Ficha-INS	E3 + E4: incluir nivel de alerta operativo.	1.00	Añadir NIVEL_ALERTA (ordinal) con umbrales de tasa percentilares.

14.4 Piloto y confiabilidad adaptada

Piloto end-to-end sobre 10-15% de N (≈ 80-120 SKUs no incluidos en la muestra definitiva), estratificado por clase ABC. Criterio de éxito: ≥ 95% de SKUs completan el pipeline, tiempo ≤ 6 h y logs completos. El α de Cronbach (1951) no aplica a instrumentos de extracción deterministas. En su lugar se aplican cuatro métricas equivalentes: (a) reproducibilidad determinista 100% (hash MD5 idéntico); (b) walk-forward stability con CV(MAE) ≤ 15% entre ventanas; (c) Cohen's κ inter-fuentes ≥ 0.75 (SIVIGILA vs. Secretaría Distrital); (d) Kendall's W inter-expertos ≥ 0.70 sobre la BOM-quirúrgica. Test-retest adaptado: re-extracción SAP al mes con Pearson r ≥ 0.95; revalidación BOM a 4 semanas con concordancia ≥ 90%; re-scraping a 7 días con hash idéntico (boletines inmutables).

XV. Plan de análisis

Siguiendo a Hair et al. (2019), Field (2018) y Hernández-Sampieri y Mendoza (2018), el plan asigna a cada OE una técnica coherente con la escala de medición, verifica supuestos antes de aplicar y selecciona software reproducible.

15.1 Stack oficial de software

Python 3.11+ con pandas, numpy, pyarrow, scipy.stats, statsmodels, scikit-learn, Optuna, TensorFlow/Keras, matplotlib y seaborn. Seguimiento de experimentos con MLflow y versionado de datasets con DVC. Reproducibilidad garantizada con requirements.txt y random_seed fijo.

15.3 Verificación de supuestos

Supuestos clásicos (Field, 2018): normalidad —Shapiro-Wilk para $n<5000$, Jarque-Bera para $n\geq5000$, $p > 0.05$—; homocedasticidad —Levene para grupos ABC, $p > 0.05$—; e independencia por diseño con Durbin-Watson para regresión. Cuando algún supuesto falla, se aplican alternativas no paramétricas: Wilcoxon signed-rank, Mann-Whitney U y Kruskal-Wallis. Supuestos específicos de series de tiempo: estacionariedad (ADF + KPSS), ausencia de autocorrelación residual (Ljung-Box, lag = 10), homocedasticidad condicional (ARCH-LM), no-linealidad detectable (BDS), estacionariedad del loss differential para Diebold-Mariano y mínimo de ventanas walk-forward ≥ 30.

15.4 Mapeo de técnicas clásicas de Hair et al. (2019)

ANOVA aplica para comparar ΔMAE entre clústeres ABC. El t-test pareado se reemplaza por Diebold-Mariano por la dependencia temporal. Chi² de independencia no aplica al no haber dos variables categóricas centrales. La regresión lineal múltiple se usa como benchmark secundario. PCA es opcional si las features exógenas superan 30. SPC (Montgomery, 2017) se usa para monitorear el error del modelo en operación. K-means complementa la clasificación ABC para segmentar SKUs por perfil de error.

15.5 Plan de reporte

Cada objetivo genera tablas y gráficos estandarizados: OE1 — descomposición STL, histograma de error y diagrama de Pareto; OE2 — curvas de aprendizaje, ACF/PACF de residuos, importancia de features (SHAP); OE3 — box-plots, scatter pronóstico vs. real, p-valores Diebold-Mariano y heat-map de mejora por clúster × horizonte. Análisis cualitativo y mixto: no aplican; el estudio es 100% cuantitativo y la triangulación se realiza entre fuentes y entre métodos estadísticos.

15.2 Matriz de coherencia analítica

Objetivo	Variable	Escala	Técnica	Supuestos	Software
OE1 — Diagnóstico línea base	V2 Error reactivo + ABC.	Razón; ordinal (ABC).	EDA + descomposición STL + estadística descriptiva + Pareto.	Estacionariedad (ADF, KPSS); autocorrelación (Ljung-Box); outliers IQR 1.5×; completitud ≥ 70%.	pandas, numpy, statsmodels, scipy.
OE2 — Entrenamiento ARIMA-LSTM	V1 Modelo + V3 + V4.	Razón, intervalo, nominal.	ARIMA + LSTM + feature engineering + Optuna + walk-forward.	Estacionariedad post-diferenciación (ADF); residuos no autocorrelacionados (Ljung-Box); homocedasticidad condicional (ARCH-LM); no-linealidad (BDS).	TensorFlow/Keras, statsmodels, scikit-learn, Optuna, MLflow.
OE3 — Verificación de la mejora	V2 Exactitud diferencial.	Razón.	Walk-forward + Diebold-Mariano + IC bootstrap + k-means + Wilcoxon.	Estacionariedad del loss differential; normalidad asintótica DM; ventanas ≥ 30.	scipy.stats, statsmodels, scikit-learn.cluster, numpy.random.

Anexo único — Resumen de formatos operativos

El proyecto cuenta con siete formatos operativos detallados (consentimiento institucional e individual, invitación al experto, hoja de evaluación de juicio, bitácora operativa, registro de piloto y pseudocódigo del pipeline). Por economía de extensión del documento principal, los formatos completos se entregan en un cuaderno de anexos separado disponible en la carpeta del proyecto. A continuación se resumen sus contenidos clave:

Formato	Contenido principal
A. Consentimiento institucional	Convenio con la Clínica Los Cobos para acceso a datos SAP, con base legal Ley 1581/2012 y Helsinki, anonimización frente a identificadores de pacientes y firmas del representante legal y del coordinador del Grupo 10.
B. Consentimiento individual	Formato individual para informantes clave (farmacia, compras, TI, programación quirúrgica) con voluntariedad, confidencialidad, derecho a retirarse, autorización de grabación y derechos Habeas Data.
C. Invitación al experto validador	Carta formal a expertos del panel de validación con descripción del proyecto, alcance de la evaluación (≤ 30 min) y reconocimiento en agradecimientos.
D. Hoja de evaluación de experto	Plantilla con 16 filas (4 instrumentos × 4 dimensiones) en escala 1-4 + observaciones generales + autorización de reconocimiento.
E. Bitácora operativa	9 campos estandarizados: ID, fecha-hora, fase, tipo de evento, descripción, decisión, responsable, seguimiento y verificación de cierre.
F. Registro de piloto	Formato con tamaño de piloto, estratificación ABC, cobertura del pipeline, tiempo, métricas preliminares MAE/RMSE/MAPE y decisión de escalamiento.
G. Pseudocódigo del pipeline	Script Python con extracción SAP, validación de integridad, pruebas ADF/KPSS, modelo ARIMA-LSTM con Optuna, validación de supuestos (Ljung-Box, ARCH-LM), evaluación walk-forward + Diebold-Mariano + bootstrap y registro en MLflow.

XV. Referencias

American Medical Association. (2013). Declaración de Helsinki — Principios éticos para las investigaciones médicas en seres humanos.

American Psychological Association. (2020). Publication Manual of the American Psychological Association (7th ed.).

Anderson, L. W., & Krathwohl, D. R. (2001). A taxonomy for learning, teaching, and assessing: A revision of Bloom's taxonomy of educational objectives. Longman.

Arias, F. G. (2012). El proyecto de investigación: Introducción a la metodología científica (6.ª ed.). Episteme.

Atek, S., Bianchini, F., De Vito, C., Cardinale, V., Novelli, S., Pesaresi, C., Eugeni, M., Mecella, M., Rescio, A., Petronzio, L., Vincenzi, A., Pistillo, P., Giusto, G., Pasquali, G., Alvaro, D., Villari, P., Mancini, M., & Gaudenzi, P. (2023). A predictive decision support system

for coronavirus disease 2019 response management and medical logistic planning. Digital Health, 9, 1-20. https://doi.org/10.1177/20552076231185475

Baruch, Y., & Holtom, B. C. (2008). Survey response rate levels and trends in organizational research. Human Relations, 61(8), 1139-1160. https://doi.org/10.1177/0018726708094863

Bassiouni, M. M., Chakrabortty, R. K., Hussain, O. K., & Rahman, H. F. (2023). Advanced deep learning approaches to predict supply chain risks under COVID-19 restrictions. Expert Systems With Applications, 211, 118604. https://doi.org/10.1016/j.eswa.2022.118604

Bernal, C. A. (2016). Metodología de la investigación (4.ª ed.). Pearson.

Cohen, J. (1960). A coefficient of agreement for nominal scales. Educational and Psychological Measurement, 20(1), 37-46.

Congreso de la República de Colombia. (2008). Ley 1266 de 2008 (Habeas Data). Diario Oficial 47.219.

Congreso de la República de Colombia. (2009). Ley 1341 de 2009 (Ley TIC). Diario Oficial 47.426.

Congreso de la República de Colombia. (2012). Ley 1581 de 2012 (Protección de Datos Personales). Diario Oficial 48.587.

Creswell, J. W., & Creswell, J. D. (2018). Research design: Qualitative, quantitative, and mixed methods approaches (5th ed.). SAGE.

Cronbach, L. J. (1951). Coefficient alpha and the internal structure of tests. Psychometrika, 16(3), 297-334.

Denzin, N. K. (1978). The research act: A theoretical introduction to sociological methods (2nd ed.). McGraw-Hill.

DeVellis, R. F. (2017). Scale development: Theory and applications (4th ed.). SAGE.

Diebold, F. X., & Mariano, R. S. (1995). Comparing predictive accuracy. Journal of Business & Economic Statistics, 13(3), 253-263.

Douaioui, K., Oucheikh, R., Benmoussa, O., & Mabrouki, C. (2024). Machine learning and deep learning models for demand forecasting in supply chain management: A critical review. Applied System Innovation, 7(5), 93. https://doi.org/10.3390/asi7050093

Escobar, J., & Cuervo, Á. (2008). Validez de contenido y juicio de expertos: una aproximación a su utilización. Avances en Medición, 6(1), 27-36.

Field, A. (2018). Discovering statistics using IBM SPSS Statistics (5th ed.). SAGE.

Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). Multivariate data analysis (8th ed.). Cengage.

Hasni, M., Babai, M. Z., & Rostami-Tabar, B. (2024). A hybrid LSTM method for forecasting demands of medical items in humanitarian operations. International Journal of Production Research, 62(17), 6046-6063. https://doi.org/10.1080/00207543.2024.2306904

Hernández-Sampieri, R., & Mendoza, C. P. (2018). Metodología de la investigación: las rutas cuantitativa, cualitativa y mixta. McGraw-Hill.

Jain, S., Agrawal, S., Mohapatra, E., & cols. (2024). A novel ensemble ARIMA-LSTM approach for evaluating COVID-19 cases and future outbreak preparedness. Health Care Science, 3(6), 409-425. https://doi.org/10.1002/hcs2.123

Kaur, A., & Prakash, G. (2025). Intelligent inventory management: AI-driven solution for the pharmaceutical supply chain. Societal Impacts, 5, 100109. https://doi.org/10.1016/j.socimp.2025.100109

Kerlinger, F. N., & Lee, H. B. (2002). Investigación del comportamiento: Métodos de investigación en ciencias sociales (4.ª ed.). McGraw-Hill.

Koç, E., & Türkoğlu, M. (2022). Forecasting of medical equipment demand and outbreak spreading based on deep long short-term memory network: The COVID-19 pandemic in Turkey. Signal, Image and Video Processing, 16, 613-621. https://doi.org/10.1007/s11760-020-01847-5

Lawshe, C. H. (1975). A quantitative approach to content validity. Personnel Psychology, 28(4), 563-575.

Likert, R. (1932). A technique for the measurement of attitudes. Archives of Psychology, 22(140), 1-55.

Montgomery, D. C. (2017). Design and analysis of experiments (9th ed.). Wiley.

Morales, P. (2006). Medición de actitudes en psicología y educación (3.ª ed.). Universidad Pontificia Comillas.

Nunnally, J. C. (1978). Psychometric theory (2nd ed.). McGraw-Hill.

Ñaupas, H., Valdivia, M., Palacios, J., & Romero, H. (2019). Metodología de la investigación cuantitativa-cualitativa y redacción de la tesis (5.ª ed.). Ediciones de la U.

Polo-Triana, S., Gutierrez, J. C., & Leon-Becerra, J. (2024). Integration of machine learning in the supply chain for decision making: A systematic literature review. Journal of Industrial Engineering and Management, 17(2). https://doi.org/10.3926/jiem.6403

Presidencia de la República de Colombia. (2013). Decreto 1377 de 2013.

Stevens, S. S. (1946). On the theory of scales of measurement. Science, 103(2684), 677-680.

Taylor, S. J., & Bogdan, R. (1987). Introducción a los métodos cualitativos de investigación. Paidós.

Yin, R. K. (2018). Case study research and applications: Design and methods (6th ed.). SAGE.