



**FACULTAD DE POSTGRADO  
TRABAJO FINAL DE GRADUACIÓN**

**ANALÍTICA PREDICTIVA EN LA NUBE: ANÁLISIS  
LONGITUDINAL DE LA DEMANDA DE  
MEDICAMENTOS CRÍTICOS MEDIANTE GRADIENT  
BOOSTING EN FARMACIAS SIMAN**

**SUSTENTADO POR:**

**GARY GONZÁLEZ ZEPEDA  
NAYRA NICOLLE VALLE MARTÍNEZ**

**PREVIA INVESTIDURA AL TÍTULO DE**

**MÁSTER EN  
GESTIÓN DE TECNOLOGÍAS DE LA INFORMACIÓN**

**TEGUCIGALPA, FRANCISCO MORAZÁN, HONDURAS, C.A.**

**FEBRERO, 2026**

**UNIVERSIDAD TECNOLÓGICA CENTROAMERICANA  
UNITEC**

**FACULTAD DE POSTGRADO**

**AUTORIDADES UNIVERSITARIAS**

**RECTORA**

**ROSALPINA RODRÍGUEZ**

**VICERRECTOR ACADÉMICO NACIONAL  
JAVIER ABRAHAM SALGADO LEZAMA**

**SECRETARIO GENERAL**

**ROGER MARTÍNEZ MIRALDA**

**DECANA FACULTAD DE POSTGRADO  
ANA DEL CARMEN RETTALLY VARGAS**

**ANALÍTICA PREDICTIVA EN LA NUBE: ANÁLISIS  
LONGITUDINAL DE LA DEMANDA DE  
MEDICAMENTOS CRÍTICOS MEDIANTE GRADIENT  
BOOSTING EN FARMACIAS SIMAN**

**TRABAJO PRESENTADO EN CUMPLIMIENTO DE LOS  
REQUISITOS EXIGIDOS PARA OPTAR AL TÍTULO DE  
MÁSTER EN**

**GESTIÓN DE TECNOLOGÍAS DE LA INFORMACIÓN**

**ASESOR**

**JORGE RAÚL MARADIAGA CHIRINOS**

**MIEMBROS DE LA TERNA:**

**KEVIN EDUARDO FUNEZ FUNEZ  
JESUS RICARDO RODRIGUEZ RIVERA  
MANUEL SALVADOR GARCIA LACAYO**



**FACULTAD DE POSTGRADO**

**ANALÍTICA PREDICTIVA EN LA NUBE: ANÁLISIS  
LONGITUDINAL DE LA DEMANDA DE MEDICAMENTOS  
CRÍTICOS MEDIANTE GRADIENT BOOSTING EN FARMACIAS  
SIMAN**

**Gary González Zepeda**

**Nayra Nicolle Valle Martínez**

## RESUMEN

El presente trabajo propone un modelo de plataforma digital con analítica e inteligencia artificial para optimizar la gestión informacional de la cadena de suministro de medicamentos esenciales en Farmacias Siman, sucursal San Pedro Sula. La iniciativa surge ante la persistente problemática de quiebres de stock y la dispersión de datos de inventario y ventas, que dificultan la toma de decisiones oportunas. La investigación, de enfoque mixto y alcance descriptivo, se centró en el diseño conceptual y de información para validar la factibilidad técnica en contextos de datos limitados. Como resultados principales, se identificaron seis requisitos críticos para el Producto Mínimo Viable y se seleccionó el algoritmo XGBoost como motor predictivo, alcanzando un Error Porcentual Absoluto Medio (MAPE) del 4.01% en el horizonte óptimo de 14 días. La arquitectura empresarial se especificó conforme a TOGAF ADM, empleando una infraestructura Serverless en Google Cloud Platform (Vertex AI, BigQuery, Cloud Run y Looker Studio) que garantiza escalabilidad y bajo costo operativo. La evaluación integral del sistema obtuvo una puntuación de 89/100 (Altamente Viable), demostrando la capacidad de generar un 71.7% de alertas accionables que anticipan el desabastecimiento. La propuesta se alinea con los marcos NIST AI RMF 1.0 y NIST CSF 2.0, cumpliendo con las normativas hondureñas de salud y protección de datos. Asimismo, se fundamenta en las teorías de la Cuarta Revolución Industrial y la computación en la nube, fortaleciendo la capacidad de Farmacias Siman para responder a disrupciones globales y contribuyendo a las metas de los ODS 3 y 9 de la ONU. Los hallazgos confirman que es posible desplegar soluciones analíticas robustas en microentornos farmacéuticos, mejorando la disponibilidad continua de medicamentos esenciales mediante decisiones basadas en datos.

**Palabras claves:** Cadena de suministro farmacéutica, inteligencia artificial, analítica predictiva, gestión informacional, Farmacias Siman, Honduras.



**GRADUATE SCHOOL**

**ANALÍTICA PREDICTIVA EN LA NUBE: ANÁLISIS  
LONGITUDINAL DE LA DEMANDA DE MEDICAMENTOS  
CRÍTICOS MEDIANTE GRADIENT BOOSTING EN FARMACIAS  
SIMAN**

**Gary González Zepeda**

**Nayra Nicolle Valle Martínez**

## ABSTRACT

This work proposes a digital platform model with analytics and artificial intelligence to optimize the informational management of the essential medicines supply chain at Farmacias Siman, San Pedro Sula branch. The initiative arises from the persistent problem of stock-outs and the dispersion of inventory and sales data, which hinder timely decision-making. The research, with a mixed approach and descriptive scope, focused on the conceptual and informational design to validate technical feasibility in limited-data contexts. As main results, six critical requirements were identified for the Minimum Viable Product, and the XGBoost algorithm was selected as the predictive engine, achieving a Mean Absolute Percentage Error (MAPE) of 4.01% in the optimal horizon of 14 days. The enterprise architecture was specified according to TOGAF ADM, employing a Serverless infrastructure on Google Cloud Platform (Vertex AI, BigQuery, Cloud Run, and Looker Studio) that guarantees scalability and low operating cost. The comprehensive evaluation of the system obtained a score of 89/100 (Highly Viable), demonstrating the capability to generate 71.7% of actionable alerts that anticipate shortages. The proposal aligns with the NIST AI RMF 1.0 and NIST CSF 2.0 frameworks, complying with Honduran health and data protection regulations. Likewise, it is based on the theories of the Fourth Industrial Revolution and cloud computing, strengthening Farmacias Siman's capacity to respond to global disruptions and contributing to UN SDGs 3 and 9. The findings confirm that it is possible to deploy robust analytical solutions in pharmaceutical micro-environments, improving the continuous availability of essential medicines through data-driven decisions.

**Keywords:** Pharmaceutical supply chain, artificial intelligence, predictive analytics, informational management, Farmacias Siman, Honduras.

## DEDICATORIA

**Gary González Zepeda:** A Dios, por ser mi guía y fortaleza en cada paso de este camino, permitiéndonos culminar con éxito esta meta académica. A mi esposa e hijas, por su amor incondicional, sus sacrificios y por ser el motor que me impulsó a nunca desistir. Gracias por creer en mí y apoyarme durante las largas jornadas de estudio e investigación que este proyecto demandó.

A la Universidad Tecnológica Centroamericana (UNITEC), nuestra alma mater, por brindarme las herramientas y conocimientos necesarios para crecer como profesional en la Gestión de Tecnologías de la Información. A mis mentores y docentes de la Maestría en Gestión de Tecnologías de la Información, cuya exigencia y conocimientos me han preparado para aportar valor a la sociedad hondureña mediante la innovación tecnológica.

Por último y no menos importante a Farmacias Siman, por abrirnos las puertas y permitirnos desarrollar esta propuesta que busca impactar positivamente en la salud de la población.

**Nayra Nicolle Valle Martínez:** A Dios, por ser mi guía y fortaleza en cada paso de este camino, iluminando mis decisiones y permitiéndome culminar con éxito esta meta académica. A mis padres, por su amor incondicional, por enseñarme el valor del esfuerzo y por acompañarme con paciencia y fe durante todo este proceso. Gracias por cada sacrificio, cada palabra de ánimo y por ser el pilar que ha sostenido mis sueños desde el inicio. Este logro también es de ustedes.

A mi novio, Kevin, por su apoyo y comprensión en las largas jornadas de estudio e investigación. Gracias por acompañarme y motivarme a seguir adelante incluso en los momentos más desafiantes.

A la Universidad Tecnológica Centroamericana (UNITEC), nuestra alma mater, por brindarme las herramientas y conocimientos necesarios para crecer como profesional en el ámbito de la Gestión de Tecnologías de la Información. A mis docentes y mentores de la maestría, cuya dedicación y exigencia han sido fundamentales para formarme con excelencia y compromiso.

Por último, a Farmacias Siman, por abrirnos las puertas y permitirnos desarrollar esta propuesta orientada a contribuir positivamente a la salud y al bienestar de la población hondureña.

## **AGRADECIMIENTO**

A Dios, por concedernos la sabiduría, salud y perseverancia necesarias para completar este importante ciclo profesional.

A la **Universidad Tecnológica Centroamericana (UNITEC)**, nuestra casa de estudios, por brindarnos un programa de excelencia que ha fortalecido nuestras competencias estratégicas y técnicas para afrontar los retos de la transformación digital en el país.

A nuestro asesor, **Jorge Raúl Maradiaga Chirinos**, por su invaluable guía, paciencia y acertadas observaciones metodológicas durante todo el proceso de investigación. Su experiencia y criterio fueron fundamentales para la estructuración y éxito de este trabajo final.

A **Farmacias Siman**, especialmente al personal de la sucursal San Pedro Sula, por su apertura y colaboración al facilitarnos el acceso a la información operativa y participar en el levantamiento de requisitos. Su disposición fue la piedra angular para validar la viabilidad práctica de esta propuesta.

Finalmente, a nuestras familias, por ser nuestro soporte incondicional en las largas noches de estudio y por comprender la importancia de este logro para nuestro crecimiento profesional.

**Gary González Zepeda y Nayra Nicolle Valle Martínez**

# ÍNDICE DE CONTENIDO

<b>RESUMEN .....</b>	<b>viii</b>
<b>ABSTRACT.....</b>	<b>x</b>
<b>DEDICATORIA.....</b>	<b>xi</b>
<b>AGRADECIMIENTO .....</b>	<b>xii</b>
<b>ÍNDICE DE ILUSTRACIÓN .....</b>	<b>xx</b>
<b>ÍNDICE DE TABLA.....</b>	<b>xxii</b>
<b>CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN .....</b>	<b>1</b>
<b>1.1 INTRODUCCIÓN.....</b>	<b>1</b>
<b>1.2 ANTECEDENTES DEL PROBLEMA .....</b>	<b>2</b>
<b>1.3 PLANTEAMIENTO DEL PROBLEMA.....</b>	<b>5</b>
<b>1.4 PREGUNTAS DEL PROYECTO (FRAMEWORK P.I.C.O.).....</b>	<b>6</b>
1.4.1 PREGUNTA GENERAL .....	6
1.4.2 PREGUNTAS ESPECÍFICAS.....	7
<b>1.5 OBJETIVOS DEL PROYECTO .....</b>	<b>8</b>
1.5.1 OBJETIVO GENERAL .....	8
1.5.2 OBJETIVOS ESPECÍFICOS.....	8
<b>1.6 JUSTIFICACIÓN .....</b>	<b>9</b>
<b>CAPÍTULO II. MARCO TEÓRICO.....</b>	<b>13</b>
<b>2.1 MACROENTORNO.....</b>	<b>13</b>
2.1.1 ANÁLISIS COMPARATIVO PESTEL (UE, EE. UU., SUDAMÉRICA Y HONDURAS) .....	13
2.1.2 ESCASEZ GLOBAL DE MEDICAMENTOS ESENCIALES.....	18
2.1.3 TRANSFORMACIÓN DIGITAL EN CADENAS FARMACÉUTICAS.....	19
2.1.4 INTEROPERABILIDAD Y GESTIÓN DE DATOS EN SALUD .....	21
2.1.5 ÉTICA, GOBERNANZA DE IA Y CIBERSEGURIDAD EN SALUD.....	22
2.1.6 IMPACTO DE DISRUPCIONES GLOBALES EN CADENAS FARMACÉUTICAS .....	23
2.1.7 CONVERGENCIA TECNOLÓGICA Y ECOSISTEMAS DIGITALES EMERGENTES.....	25

2.1.8 MODELOS OPERATIVOS Y GESTIÓN DEL SERVICIO PARA PLATAFORMAS FARMACÉUTICAS .....	25
2.1.8.1 NIST CSF 2.0.....	26
2.1.8.2 NIST AI RMF 1.0 .....	27
<b>2.2 MICROENTORNO .....</b>	<b>29</b>
2.2.1 ANÁLISIS DE COMPETITIVIDAD REGIONAL (MODELO DE LAS 5 FUERZAS) .....	29
2.2.2 ANÁLISIS COMPETITIVO: SIMAN FRENTE A REFERENTES LOCALES Y REGIONALES.....	32
2.2.3 ESTADO DE LA CADENA DE SUMINISTRO FARMACÉUTICO EN HONDURAS.....	33
2.2.4 HOJA DE RUTA DE TRANSFORMACIÓN DIGITAL EN SALUD EN HONDURAS.....	35
2.2.5 MARCOS ESTRATÉGICOS IS4H EN HONDURAS .....	35
2.2.6 SISTEMAS DE INFORMACIÓN PARA LA SALUD EN HONDURAS .....	36
2.2.7 CONTEXTO ORGANIZACIONAL: FARMACIAS SIMAN .....	37
2.2.7.1 PROCESOS OPERATIVOS Y CAPACIDADES ACTUALES.....	37
2.2.7.2 INFRAESTRUCTURA Y CAPACIDADES TECNOLÓGICAS DE INFORMACIÓN DISPONIBLES.....	38
2.2.7.3 DATOS DISPONIBLES, CALIDAD Y RESTRICCIONES DE USO.....	39
<b>2.3 TEORÍAS DE SUSTENTO.....</b>	<b>40</b>
2.3.1 CUARTA REVOLUCIÓN INDUSTRIAL APLICADA A SALUD .....	42
2.3.2 ANALÍTICA PREDICTIVA Y APRENDIZAJE AUTOMÁTICO EN CADENAS DE SUMINISTROS .....	43
2.3.3 COMPUTACIÓN EN LA NUBE Y ARQUITECTURA EMPRESARIAL PARA SISTEMAS FARMACÉUTICOS.....	44
<b>2.4 ANÁLISIS DE LAS METODOLOGÍAS.....</b>	<b>46</b>
2.4.1 MACHINE LEARNING PARA DESARROLLO DE MODELO PREDICTIVO .....	47
2.4.1.1 EVOLUCIÓN Y SELECCIÓN DE ENFOQUES EN LA LITERATURA ESPECIALIZADA .....	47
2.4.1.2 JUSTIFICACIÓN TEÓRICA: EXPLICABILIDAD Y GOBERNANZA DEL	

ALGORITMO.....	48
2.4.2 TOGAF ADM PARA ESPECIFICACIÓN ARQUITECTÓNICA .....	48
2.4.3 ANÁLISIS COMPARATIVO INTEGRAL Y APORTE METODOLÓGICO.....	49
<b>2.5 ANTECEDENTES DE LAS METODOLOGÍAS .....</b>	<b>51</b>
2.5.1 EVOLUCIÓN DEL MACHINE LEARNING FARMACÉUTICO .....	51
2.5.1.1 TRANSICIÓN HACIA APRENDIZAJE AUTOMÁTICO ESPECIALIZADO ..	51
2.5.1.2 ERA CONTEMPORÁNEA: ESPECIALIZACIÓN FARMACÉUTICA.....	51
2.5.2 DESARROLLO DE ARQUITECTURAS EMPRESARIALES EN SALUD.....	52
2.5.2.1 MARCOS ESPECIALIZADOS REGIONALES .....	52
2.5.2.2 ANTECEDENTE NACIONAL: EL SISTEMA SALMI Y LA GESTIÓN LOGÍSTICA .....	52
2.5.3 CONVERGENCIA METODOLÓGICA .....	53
2.5.3.1 FUNDAMENTOS EMPÍRICOS DE LA CONVERGENCIA.....	53
2.5.3.2 INTEGRACIÓN ARQUITECTÓNICA VALIDADA.....	53
2.5.3.3 VALIDACIÓN MEDIANTE MARCOS DE GESTIÓN DE RIESGOS .....	54
2.5.3.4 EVIDENCIA DE APLICABILIDAD SECTORIAL.....	54
2.5.3.5 INFRAESTRUCTURA TECNOLÓGICA HABILITADORA.....	55
2.5.3.6 IMPLICACIONES PARA IMPLEMENTACIÓN .....	55
<b>2.6 ANÁLISIS CRÍTICO DE LAS METODOLOGÍAS .....</b>	<b>57</b>
2.6.1 EVALUACIÓN CRÍTICA DE MACHINE LEARNING CON DATOS LIMITADOS .....	57
2.6.2 EVALUACIÓN CRÍTICA DE LA ARQUITECTURA SERVERLESS .....	58
2.6.2.1 JUSTIFICACIÓN FINANCIERA Y OPERATIVA .....	58
2.6.2.2 RIESGOS DE DEPENDENCIA Y LATENCIA.....	58
2.6.3 SÍNTESIS DE VIABILIDAD TÉCNICA.....	59
<b>2.7 HERRAMIENTAS.....</b>	<b>60</b>
2.7.1 EVALUACIÓN TÉCNICA COMPARATIVA (GCP VS. AWS VS. AZURE) .....	61
2.7.1.1 ANÁLISIS DE COSTOS UNITARIOS (UNIT ECONOMICS) .....	63
2.7.2 PLATAFORMA DE DESARROLLO ANALÍTICO .....	64
2.7.2.1 VERTEX AI.....	64
2.7.2.2 BIGQUERY .....	65

2.7.2.3 HERRAMIENTAS DE OBSERVABILIDAD.....	66
2.7.2.4 PYTHON .....	67
2.7.2.5 LOOKER STUDIO.....	70
2.7.2.6 CLOUD FUNCTIONS Y PUB/SUB.....	71
2.7.2.7 ARQUITECTURA SERVERLESS.....	72
2.7.3 INSTRUMENTOS DE DOCUMENTACIÓN ARQUITECTÓNICA .....	73
2.7.3.1 CATÁLOGO DE DATOS Y DICCIONARIO EMPRESARIAL.....	73
2.7.3.2 MATRIZ DE TRAZABILIDAD .....	74
<b>2.8 CONCEPTUALIZACIÓN .....</b>	<b>75</b>
<b>2.9 MARCO LEGAL .....</b>	<b>80</b>
2.9.1 MARCO LEGAL INTERNACIONAL.....	80
2.9.1.1 ESTÁNDARES DE SALUD DIGITAL.....	80
2.9.1.2 FRAMEWORKS DE IA ÉTICA .....	81
2.9.1.3 MARCO DE PROTECCIÓN DE DATOS Y HABEAS DATA.....	82
2.9.2 MARCO LEGAL NACIONAL .....	83
2.9.2.1 REGULACIÓN FARMACÉUTICA OPERATIVA .....	83
2.9.2.2 HABILITADORES DE GOBIERNO DIGITAL .....	85
2.9.3 IMPLICACIONES PARA DISEÑO TÉCNICO .....	86
<b>CAPÍTULO III. METODOLOGÍA DE LA INVESTIGACIÓN .....</b>	<b>88</b>
<b>3.1 ENFOQUE .....</b>	<b>88</b>
3.1.1 FASE 1: CUALITATIVA - ESPECIFICACIÓN DEL DOMINIO (QUAL) .....	88
3.1.2 MECANISMO DE INTEGRACIÓN: INGENIERÍA DE CARACTERÍSTICAS .....	89
3.1.3 FASE 2: CUANTITATIVA - VALIDACIÓN EMPÍRICA (QUAN) .....	90
<b>3.2 ALCANCE .....</b>	<b>92</b>
<b>3.3 DISEÑO DE LA INVESTIGACIÓN .....</b>	<b>93</b>
3.3.1 DIAGRAMA DE TRAZABILIDAD DEL FLUJO DE INVESTIGACIÓN (ARQUITECTURA GCP) .....	94
<b>3.4 POBLACIÓN.....</b>	<b>94</b>
3.4.1 COMPONENTE DE DATOS (NÚCLEO PREDICTIVO) .....	95
3.4.2 COMPONENTE DE ACTORES (VALIDACIÓN CUALITATIVA) .....	95
3.4.3 COMPONENTE DE PROCESOS .....	96

<b>3.5 MUESTRA.....</b>	<b>96</b>
3.5.1 JUSTIFICACIÓN TÉCNICA DEL CENSO DE DATOS.....	97
3.5.2 JUSTIFICACIÓN OPERATIVA DEL CENSO DE ACTORES .....	97
<b>3.6 TÉCNICA DE MUESTREO .....</b>	<b>98</b>
<b>3.7 CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN .....</b>	<b>98</b>
<b>3.8 ESQUEMA DE VARIABLES.....</b>	<b>100</b>
<b>3.9 OPERACIONALIZACIÓN DE VARIABLES .....</b>	<b>101</b>
3.9.1 REQUISITOS DEL MODELO INFORMACIONAL .....	101
3.9.2 ESPECIFICACIONES TÉCNICAS DE IA .....	101
3.9.3 ARQUITECTURA EN LA NUBE .....	102
3.9.4 MARCO DE EVALUACIÓN DE VIABILIDAD.....	103
<b>3.10 TÉCNICAS, INSTRUMENTOS, PROCEDIMIENTOS Y PLAN DE ANÁLISIS</b>	<b>104</b>
3.10.1 IDENTIFICAR REQUISITOS.....	104
3.10.2 DEFINIR TÉCNICAS DE IA .....	106
3.10.3 ESPECIFICAR ARQUITECTURA.....	107
3.10.4 MARCO DE EVALUACIÓN.....	109
<b>3.11 FUENTES DE INFORMACIÓN.....</b>	<b>110</b>
3.11.1 FUENTES PRIMARIAS.....	110
3.11.2 FUENTES SECUNDARIAS .....	111
3.11.3 DELIMITACIÓN Y EXCLUSIÓN DE FUENTES (PROVEEDORES EXTERNOS)	
.....	112
<b>3.12 MATRIZ METODOLÓGICA.....</b>	<b>114</b>
<b>CAPÍTULO IV. RESULTADOS Y ANÁLISIS.....</b>	<b>120</b>
<b>4.1 RESULTADOS DEL OBJETIVO ESPECÍFICO 1: IDENTIFICACIÓN DE</b>	
<b>REQUISITOS.....</b>	<b>120</b>
4.1.1 INSTRUMENTOS APLICADOS Y VALIDACIÓN.....	121
4.1.2 PARTICIPANTES Y CARACTERÍSTICAS .....	124
4.1.3 DESCRIPCIÓN DE RESULTADOS POR SECCIÓN DEL CUESTIONARIO .....	125
4.1.4 ANÁLISIS DE RESULTADOS: TRIANGULACIÓN Y PRIORIZACIÓN .....	133
4.1.5 HALLAZGOS ENCONTRADOS Y RESPUESTA AL OBJETIVO ESPECÍFICO 1	
.....	134

<b>4.2 RESULTADOS DEL OBJETIVO ESPECÍFICO 2: DEFINICIÓN DE TÉCNICAS DE IA.....</b>	<b>135</b>
4.2.1 MARCO CONCEPTUAL DEL ENFOQUE DE IA PARA REPOSICIÓN.....	135
4.2.2 INSTRUMENTOS Y CONCEPTOS TÉCNICOS .....	135
4.2.3 RESULTADOS DEL BENCHMARKING COMPARATIVO .....	136
4.2.4 ANÁLISIS DEL SESGO Y RIESGO OPERATIVO .....	139
4.2.5 SELECCIÓN FINAL (SCORING MULTICRITERIO).....	141
4.2.6 ANÁLISIS DEL HORIZONTE ÓPTIMO: ¿POR QUÉ 14 DÍAS?.....	142
4.2.7 HALLAZGOS Y RESPUESTA AL OBJETIVO .....	143
<b>4.3 RESULTADOS DEL OBJETIVO ESPECÍFICO 3: ESPECIFICACIÓN ARQUITECTÓNICA .....</b>	<b>144</b>
4.3.1 INSTRUMENTOS APLICADOS.....	144
4.3.2 PROCESO DE DISEÑO (TOGAF ADM).....	145
4.3.3 DESCRIPCIÓN DE LA ARQUITECTURA ESPECIFICADA.....	146
4.3.3.1 TRAZABILIDAD DE REQUISITOS .....	148
4.3.3.2 VALIDACIÓN DE CALIDAD (WELL-ARCHITECTED) .....	150
4.3.3.3 DISEÑO DE CONFIABILIDAD (SLO).....	151
4.3.4 HALLAZGOS PRINCIPALES DE LA ESPECIFICACIÓN.....	152
<b>4.4 RESULTADOS DEL OBJETIVO ESPECÍFICO 4: MARCO DE EVALUACIÓN</b>	<b>153</b>
4.4.1 INSTRUMENTOS APLICADOS.....	153
4.4.2 CARACTERIZACIÓN DE LA MUESTRA (ALCANCE DE LA EVALUACIÓN).....	154
4.4.3 DESCRIPCIÓN DE RESULTADOS: SCORING DE VIABILIDAD GLOBAL.....	155
4.4.4 ANÁLISIS DE UTILIDAD OPERATIVA DE LAS ALERTAS.....	156
4.4.5 HALLAZGOS PRINCIPALES Y SÍNTESIS PARA OBJETIVO ESPECÍFICO 4 .	158
<b>4.5 ANÁLISIS DE INFERENCIA ESTADÍSTICA.....</b>	<b>160</b>
4.5.1 ESTADÍSTICAS DESCRIPTIVAS DEL ERROR DE PREDICCIÓN .....	160
4.5.2 PRUEBA DE NORMALIDAD (SHAPIRO-WILK).....	161
4.5.3 SENSIBILIDAD AL HORIZONTE (PRUEBA DE FRIEDMAN).....	161
4.5.4 VALIDACIÓN DE SUPERIORIDAD: XGBOOST VS. LÍNEA BASE (WILCOXON).....	162
4.5.5 CONCLUSIÓN DEL ANÁLISIS DE INFERENCIA .....	163

<b>CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES.....</b>	<b>164</b>
<b>5.1 CONCLUSIONES.....</b>	<b>164</b>
5.1.1 OBJETIVO ESPECÍFICO 1: IDENTIFICACIÓN DE REQUISITOS .....	164
5.1.2 OBJETIVO ESPECÍFICO 2: ESPECIFICACIONES DE IA Y TÉCNICAS DE ANÁLISIS.....	164
5.1.3 OBJETIVO ESPECÍFICO 3: ESPECIFICACIÓN DE ARQUITECTURA.....	165
5.1.4 CONCLUSIONES DEL OBJETIVO ESPECÍFICO 4: EVALUACIÓN DE VIABILIDAD .....	165
<b>5.2 RECOMENDACIONES.....</b>	<b>165</b>
5.2.1 IMPLEMENTACIÓN ESCALONADA (MVP Y MEJORA CONTINUA).....	165
5.2.2 SANEAMIENTO DE DATOS PRIORITARIO .....	166
5.2.3 AUTOMATIZACIÓN DE LA INGESTA DE DATOS .....	166
5.2.4 GESTIÓN DE PRERREQUISITOS ORGANIZACIONALES.....	166
5.2.5 ESTRATEGIA HÍBRIDA DE AUTOMATIZACIÓN.....	166
5.2.6 DOCUMENTACIÓN Y PRUEBAS DE ESTRÉS .....	167
<b>CAPÍTULO VI. APLICABILIDAD .....</b>	<b>168</b>
<b>6.1 NOMBRE DE LA PROPUESTA.....</b>	<b>168</b>
<b>6.2 JUSTIFICACIÓN DE LA PROPUESTA .....</b>	<b>168</b>
<b>6.3 ALCANCE DE LA PROPUESTA.....</b>	<b>170</b>
6.3.1 OBJETIVO GENERAL DE LA PROPUESTA.....	170
6.3.2 OBJETIVOS ESPECÍFICOS DE LA PROPUESTA .....	170
<b>6.4 DESCRIPCIÓN Y DESARROLLO .....</b>	<b>171</b>
6.4.1 DESCRIPCIÓN.....	171
6.4.2 DESARROLLO .....	173
<b>6.5 MEDIDAS DE CONTROL .....</b>	<b>194</b>
6.5.1 CONTROL DE NIVEL DE SERVICIO (SLO TECNOLÓGICO) .....	195
6.5.2 FICHAS DE INDICADORES CLAVE DE DESEMPEÑO (KPIs OPERATIVOS) 195	
<b>6.6 CRONOGRAMA DE IMPLEMENTACIÓN.....</b>	<b>198</b>
6.6.1 DESGLOSE DE ACTIVIDADES Y DEPENDENCIAS .....	199
6.6.2 CÁLCULO DE LA RUTA CRÍTICA.....	200
6.6.3 ANÁLISIS DE HOLGURAS Y GESTIÓN DE TIEMPOS .....	200

6.6.4 CRONOGRAMA CONSOLIDADO (MVP + ESTABILIZACIÓN).....	202
<b>6.7 ANÁLISIS DE VIABILIDAD ECONÓMICA Y FINANCIERA .....</b>	<b>202</b>
6.7.1 ESTRUCTURA DE COSTOS (INVERSIÓN Y OPERACIÓN) .....	202
6.7.2 CUANTIFICACIÓN DE BENEFICIOS (MODELO DE AHORRO) .....	203
6.7.3 ANÁLISIS DE ESCENARIOS Y FLUJO DE CAJA (VAN Y TIR).....	204
6.7.4 INTERPRETACIÓN DE VIABILIDAD.....	205
<b>6.8 CONCORDANCIA DE LOS SEGMENTOS DE LA TESIS CON LA PROPUESTA</b>	
<b>206</b>	
<b>REFERENCIAS BIBLIOGRÁFICAS.....</b>	<b>209</b>
<b>ANEXOS.....</b>	<b>217</b>
ANEXO I: ENCUESTA.....	217
ANEXO II: MATRIZ DE REQUERIMIENTOS .....	218
ANEXO III: MATRIZ DE DISPONIBILIDAD Y CALIDAD DE DATOS.....	219
ANEXO IV: MATRIZ DE EVALUACIÓN DE ALGORITMOS ML .....	220
ANEXO V: SCRIPTS BACKTESTING AUTOMATIZADO .....	221
ANEXO VI: PROTOCOLO DE VALIDACIÓN WALK-FORWARD.....	221
ANEXO VII: PLANTILLA TOGAF ADM.....	221
ANEXO VIII: CHECKLIST WELL-ARCHITECTED GCP + GUÍA SRE.....	222
ANEXO IX: MARCO DE EVALUACIÓN DE VIABILIDAD .....	223
ANEXO X: MATRIZ DE UTILIDAD OPERATIVA .....	224
ANEXO XI: SCRIPT PYTHON UTILIDAD DE ALERTAS .....	225
ANEXO XII: MATRIZ DE TRAZABILIDAD REQUISITOS-COMPONENTES .....	225
ANEXO XIII: FRAGMENTO DEL INSTRUMENTO TÉCNICO - SCRIPT ETL DE EXTRACCIÓN (BIGQUERY).....	226

## ÍNDICE DE ILUSTRACIÓN

<b>Ilustración 1.</b> Diagrama de Causa-Efecto (Ishikawa) del Desabastecimiento.....	10
<b>Ilustración 2.</b> NIST CSF 2.0 — Estructura del Core y Funciones .....	26
<b>Ilustración 3.</b> NIST AI RMF 1.0 — Funciones del Core (Govern, Map, Measure, Manage).....	28

<b>Ilustración 4.</b> El Ciclo del Método de Desarrollo de Arquitectura (ADM) de TOGAF.....	45
<b>Ilustración 5.</b> Arquitectura de Vertex AI para Pronóstico de Demanda Farmacéutica .....	65
<b>Ilustración 6.</b> Arquitectura BigQuery para Consolidación Informativa .....	66
<b>Ilustración 7.</b> Sistema de Observabilidad Cloud Monitoring/Logging para Operaciones Farmacéuticas Críticas .....	67
<b>Ilustración 8.</b> Flujo de Procesamiento de Datos con Python.....	69
<b>Ilustración 9.</b> Arquitectura de Visualización con Looker Studio y BigQuery .....	70
<b>Ilustración 10.</b> Modelo de Alertas Asíncronas con Pub/Sub y Cloud Functions .....	72
<b>Ilustración 11.</b> Estructura del Catálogo de Datos y Diccionario Empresarial Farmacéutico .....	74
<b>Ilustración 12.</b> Diagrama Forense del Flujo de Datos y Procesamiento en GCP.....	94
<b>Ilustración 13.</b> Esquema de Dimensiones de Análisis del Modelo Conceptual Según Objetivos Específicos .....	100
<b>Ilustración 14.</b> Red PERT del Proceso Metodológico (OE1–OE4) .....	108
<b>Ilustración 15.</b> Distribución de utilidad percibida por requisito funcional (D1–D5).....	127
<b>Ilustración 16.</b> Distribución de importancia percibida de requisitos no funcionales (E1–E5)..	129
<b>Ilustración 17.</b> Disponibilidad de capacidades tecnológicas actuales. ....	130
<b>Ilustración 18.</b> Disponibilidad de datos históricos por participante (G1).....	132
<b>Ilustración 19.</b> Calidad percibida de datos (G2–G4).....	133
<b>Ilustración 20.</b> Comparación de MAE por algoritmo y horizonte de predicción. ....	138
<b>Ilustración 21.</b> Comparación de MAPE por algoritmo y horizonte de predicción.....	139
<b>Ilustración 22.</b> Sesgo sistemático por algoritmo (Tendencia a subestimar).....	140
<b>Ilustración 23.</b> Eficiencia computacional por algoritmo. ....	141
<b>Ilustración 24.</b> Puntuación final multicriterio.....	142
<b>Ilustración 25.</b> Fases TOGAF ADM Ejecutadas para Especificación Arquitectónica.....	146
<b>Ilustración 26.</b> ARQUITECTURA TECNOLÓGICA .....	148
<b>Ilustración 27.</b> Cumplimiento Well-Architected por Pilar .....	151
<b>Ilustración 28.</b> DISTRIBUCIÓN DEL SCORING DE VIABILIDAD .....	155
<b>Ilustración 29.</b> CUMPLIMIENTO DE CRITERIOS DE ALERTAS.....	157
<b>Ilustración 30.</b> DISTRIBUCIÓN DE ALERTAS POR NIVEL DE RIESGO.....	158
<b>Ilustración 31.</b> Dashboard General del Modelo Predictivo. ....	173
<b>Ilustración 32.</b> Flujograma de Procesamiento Asíncrono y Lógica de Alertas. ....	175

<b>Ilustración 33.</b> Pantalla de Pronóstico de Demanda. ....	178
<b>Ilustración 34.</b> Pantalla de Gestión de Inventario.....	181
<b>Ilustración 35.</b> Pantalla de Gestión de Alertas. ....	184
<b>Ilustración 36.</b> Pantalla de Catálogo de Medicamentos. ....	187
<b>Ilustración 37.</b> Pantalla de Historial de Ventas. ....	189
<b>Ilustración 38.</b> Sección de Métricas del Sistema. ....	194
<b>Ilustración 39.</b> Sección de Entrenamiento y Evaluación.....	194
<b>Ilustración 40.</b> Sección de Configuración del Sistema.....	194
<b>Ilustración 41.</b> Cronograma de implementación. ....	198
<b>Ilustración 42.</b> Trazabilidad de la investigación propuesta. ....	208

## ÍNDICE DE TABLA

<b>Tabla 1.</b> Matriz PESTEL Comparativa para Gobernanza de Datos, IA e Interoperabilidad en Salud Digital .....	14
<b>Tabla 2.</b> <i>Enfoques Internacionales para la Mitigación de la Escasez de Medicamentos Esenciales</i> .....	18
<b>Tabla 3.</b> <i>Evidencia Internacional de Aplicación de Tecnologías Digitales en Cadenas Farmacéuticas</i> .....	20
<b>Tabla 4.</b> <i>Principios Éticos para IA en Salud y su Relevancia para Plataformas Farmacéuticas</i> 22	
<b>Tabla 5.</b> Disrupciones Globales y Respuestas Documentadas en Cadenas Farmacéuticas .....	24
<b>Tabla 6.</b> Análisis comparativo de las 5 Fuerzas de Porter en Centroamérica (Retail Farmacéutico) .....	29
<b>Tabla 7.</b> Matriz de Posicionamiento Competitivo (Siman vs. Arquetipos de Mercado) .....	32
<b>Tabla 8.</b> <i>Brechas del Ecosistema Farmacéutico Hondureño y Oportunidades Analíticas</i> .....	34
<b>Tabla 9.</b> Niveles de Implementación IS4H en Honduras y su Impacto en el Sector Privado.....	35
<b>Tabla 10.</b> Sistemas de Información Farmacéutica y Sanitaria en Honduras.....	36
<b>Tabla 11.</b> Alineación de Teorías de Sustento con Objetivos Específicos.....	41
<b>Tabla 12.</b> <i>Análisis Comparativo de Enfoques Algorítmicos en Contextos de Datos Limitados</i> ..	47
<b>Tabla 13.</b> Evaluación de Marcos de Arquitectura Empresarial para Salud Digital .....	49

<b>Tabla 14.</b> Transformación del Modelo Operativo: Línea Base vs. Propuesta .....	49
<b>Tabla 15.</b> Matriz de Convergencia: Metodologías Previas en Literatura vs. Integración Propuesta .....	50
<b>Tabla 16.</b> Convergencia Metodológica: Evidencia Empírica y Aplicaciones .....	56
<b>Tabla 17.</b> Análisis de Viabilidad Técnica y Estrategias de Mitigación ante Limitaciones.....	59
<b>Tabla 18.</b> Scorecard de Evaluación Técnica de Ecosistemas Cloud.....	61
<b>Tabla 19.</b> Comparativo de Unit Economics para Inferencia Serverless (GCP vs AWS).....	63
<b>Tabla 20.</b> Matriz de Trazabilidad Requisitos-Componentes Técnicos .....	75
<b>Tabla 21.</b> Comparación de Marcos Regulatorios de IA en Salud (Internacional) .....	82
<b>Tabla 22.</b> Marco Legal Específico para Plataformas Farmacéuticas Digitales.....	85
<b>Tabla 23.</b> Matriz de Integración Metodológica (DEXPLOS): Del Hallazgo Cualitativo a la Variable Operativa .....	89
<b>Tabla 24.</b> Resumen Técnico de la Población y Muestra Censal .....	96
<b>Tabla 25.</b> Matriz de Correspondencia Población-Muestra (Censo).....	97
<b>Tabla 26.</b> Criterios de Inclusión y Exclusión por Ámbito de Estudio .....	99
<b>Tabla 27.</b> Operacionalización de Variables - Objetivo 1 .....	101
<b>Tabla 28.</b> Operacionalización de Variables - Objetivo 2 .....	102
<b>Tabla 29.</b> Operacionalización de Variables - Objetivo 3 .....	103
<b>Tabla 30.</b> Operacionalización de Variables - Objetivo 4.....	103
<b>Tabla 31.</b> Metodología para Identificación de Requisitos del Modelo Informacional .....	104
<b>Tabla 32.</b> Metodología para Selección de Técnicas de Inteligencia Artificial .....	106
<b>Tabla 33.</b> Metodología para Especificación Arquitectónica.....	107
<b>Tabla 34.</b> Metodología para Marco de Evaluación de Viabilidad .....	109
<b>Tabla 35.</b> Fuentes Primarias del Estudio.....	111
<b>Tabla 36.</b> Fuentes Secundarias del Estudio.....	111
<b>Tabla 37.</b> Instrumentos de recolección de datos para identificación de requisitos .....	122
<b>Tabla 38.</b> Perfil de Participantes del Cuestionario (N=3) .....	125
<b>Tabla 39.</b> Utilidad percibida de requisitos funcionales (RF) .....	126
<b>Tabla 40.</b> Importancia percibida de requisitos no funcionales (RNF) .....	128
<b>Tabla 41.</b> Disponibilidad de capacidades tecnológicas actuales (F1–F4).....	130
<b>Tabla 42.</b> Evaluación de disponibilidad y calidad de datos (G1–G4).....	131

<b>Tabla 43.</b> Triangulación de Evidencia (Joint Display) .....	134
<b>Tabla 44.</b> Resultados Comparativos de Benchmarking .....	137
<b>Tabla 45.</b> Resumen de Sesgo Promedio.....	139
<b>Tabla 46.</b> Matriz de Selección de Algoritmo .....	141
<b>Tabla 47.</b> Criterios para Selección de Horizonte .....	143
<b>Tabla 48.</b> Instrumentos aplicados para especificación arquitectónica .....	144
<b>Tabla 49.</b> Fases del Diseño Arquitectónico Ejecutadas .....	145
<b>Tabla 50.</b> Arquitectura Tecnológica en 4 Capas – Servicios GCP .....	147
<b>Tabla 51.</b> Síntesis de Trazabilidad: Requisitos Críticos → Componentes GCP.....	149
<b>Tabla 52.</b> Resultados Consolidados Well-Architected por Pilar.....	150
<b>Tabla 53.</b> Hallazgos Consolidados de la Especificación Arquitectónica.....	152
<b>Tabla 54.</b> Instrumentos y Criterios de Evaluación por Dimensión .....	154
<b>Tabla 55.</b> Scoring de Viabilidad Global del Sistema .....	155
<b>Tabla 56.</b> Síntesis de Hallazgos y Recomendaciones por Dimensión .....	159
<b>Tabla 57.</b> Estadísticas Descriptivas del MAE por Horizonte de Predicción.....	160
<b>Tabla 58.</b> Resultados del Test de Normalidad Shapiro-Wilk.....	161
<b>Tabla 59.</b> Prueba de Rangos con Signo de Wilcoxon (XGBoost vs SMA30 (línea base)) .....	162
<b>Tabla 60.</b> Variables por horizontes .....	190
<b>Tabla 61.</b> Ficha Técnica de Indicador: Tasa de Falsos Positivos.....	196
<b>Tabla 62.</b> Ficha Técnica de Indicador: Precisión del Modelo (MAPE).....	196
<b>Tabla 63.</b> Matriz de Actividades y Precedencias (CPM).....	199
<b>Tabla 64.</b> Cálculo de Holguras (HT).....	200
<b>Tabla 65.</b> Estimación de Inversión Inicial (CAPEX) y Costos Operativos (OPEX).....	202
<b>Tabla 66.</b> Flujo de Caja Anualizado por Escenario (USD).....	204
<b>Tabla 67.</b> Indicadores Financieros de Rentabilidad.....	204
<b>Tabla 68.</b> Matriz de Concordancia.....	206

# CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN

## 1.1 INTRODUCCIÓN

La gestión eficiente de la cadena de suministro de medicamentos esenciales representa un pilar fundamental para la salud pública, donde la ruptura del abastecimiento conlleva costos tangibles y riesgos sanitarios. En el contexto de Farmacias Siman, el diagnóstico preliminar de la operación reveló ineficiencias críticas.

En la sucursal de San Pedro Sula de Farmacias Siman, la operación registra un costo de oportunidad anual superior a US\$9,000 debido a la combinación de ventas no realizadas por quiebres de inventario (stock-outs) y mermas por caducidad derivadas de sobre-stock (ver análisis de viabilidad, sección 6.7). Este impacto económico refleja una tensión operativa crítica: cuando falta un medicamento esencial, el paciente enfrenta retrasos o sustituciones forzadas en su tratamiento, y la farmacia pierde margen directo y fidelidad del cliente. Esta "ceguera operativa" no solo erosiona la rentabilidad, sino que pone en riesgo la continuidad de los tratamientos de los pacientes. Dado este contexto, la investigación se centra en una intervención mínima viable: convertir datos transaccionales internos en pronósticos, tableros y alertas auditables, priorizando la disponibilidad de medicamentos esenciales como variable crítica de desempeño operativo en Honduras.

Este desafío local se enmarca en una tendencia regional más amplia: la transformación digital del sector salud, identificada por el Banco Interamericano de Desarrollo como una oportunidad histórica para cerrar brechas de calidad, resultados y eficiencia en la región (Bagolle et al., 2022). La pandemia de COVID-19 expuso la fragmentación y el subfinanciamiento crónico de los sistemas de información en salud, haciendo imperativa la adopción de tecnologías que mejoren la eficiencia mediante analítica avanzada y visualización de datos (Organización Panamericana de la Salud [OPS], 2021).

La presente investigación surge del interés de diseñar un modelo de información con capacidades predictivas que convierta esos datos operativos dispersos en información accionable, mitigando las pérdidas identificadas sin modificar la operación vigente. En el ámbito académico, el interés radica en contribuir al campo de la Gestión de Tecnologías de la Información

proponiendo un modelo replicable para contextos con datos limitados. Desde la perspectiva profesional, el objetivo es demostrar la viabilidad técnica de integrar inteligencia artificial para generar alertas preventivas que apoyen la toma de decisiones, alineándose con las directrices regionales de salud digital y contribuyendo a los Objetivos de Desarrollo Sostenible 3 y 9 de la Agenda 2030 (ONU, 2015).

En el marco de una investigación aplicada, el estudio adopta un enfoque mixto con diseño exploratorio secuencial (DEXPLOS), integrando una fase cualitativa para especificar requisitos (OE1) y una fase cuantitativa para validar el modelo y su utilidad (OE2–OE4), con un alcance predictivo y diseño longitudinal retrospectivo. La estrategia se basa en el análisis de series temporales históricas de ventas e inventarios mediante algoritmos de Gradient Boosting, complementado con la especificación de requisitos operativos validada por actores clave. Esta aproximación permite no solo comprender la situación actual, sino modelar matemáticamente la demanda futura para anticipar riesgos de desabastecimiento con una base científica robusta.

Los objetivos del trabajo se estructuran en cuatro componentes: identificar los requisitos funcionales y no funcionales del modelo informacional; definir el enfoque de inteligencia artificial mediante la evaluación comparativa de técnicas de Machine Learning; especificar la arquitectura en la nube que sustente el procesamiento y visualización de datos garantizando escalabilidad; y establecer un marco de evaluación que valore la viabilidad técnica del modelo predictivo y su utilidad para la toma de decisiones.

El Capítulo I desarrolla el planteamiento de la investigación, contextualizando la métrica del problema económico y delimitando el alcance predictivo. En el Capítulo II se presenta el marco teórico, incluyendo la revisión de enfoques de analítica farmacéutica. El Capítulo III describe la metodología, justificando el uso de series temporales y validación walk-forward. El Capítulo IV presenta los resultados del análisis inferencial y la comparación de modelos. El Capítulo V expone las conclusiones y recomendaciones. Finalmente, el Capítulo VI desarrolla la propuesta de aplicabilidad técnica y financiera del modelo.

## **1.2 ANTECEDENTES DEL PROBLEMA**

La disponibilidad oportuna de medicamentos esenciales es una prioridad de salud pública.

La 24.<sup>a</sup> Lista Modelo de Medicamentos Esenciales de la OMS (2025) se actualiza de forma bienal y guía la priorización de acceso y la planificación de suministros (Organización Mundial de la Salud [OMS], 2025). A nivel regional, la OPS impulsa el fortalecimiento de sistemas de información para decisiones informadas (OPS, 2024).

El concepto de medicamentos esenciales remite a fármacos destinados a satisfacer necesidades de salud prioritarias, cuya disponibilidad continua y asequible requiere sistemas de información capaces de monitorear existencias, demanda y riesgo de escasez. La implementación efectiva de este enfoque demanda capacidades de monitoreo continuo y decisiones basadas en datos. Según la Organización Mundial de la Salud (2024), ‘los medicamentos esenciales satisfacen las necesidades prioritarias de atención de salud de la población’ (sección Datos y Cifras).

Las tensiones de la última década, particularmente la pandemia de COVID-19, revelaron vulnerabilidades sistémicas que incluyen congestión logística, interrupciones productivas, rigideces regulatorias y capacidad limitada para monitorear inventarios y demanda en tiempo real. En la Región de las Américas, la OPS documentó disrupciones significativas en servicios esenciales entre 2022 y 2023, impulsando respuestas regionales para fortalecer la resiliencia operativa y subrayando la necesidad de monitoreo continuo para sostener tratamientos (OPS, 2024). Esta experiencia consolidó la transformación digital en salud como estrategia transversal para mejorar la gobernanza, la trazabilidad y la oportunidad de la información (OPS, 2021).

A nivel regional, este impulso se consolidó en 2024 con la aprobación del Plan de Acción 2024–2030. La OPS (2024) establece:

Fortalecer la gestión y la gobernanza de los sistemas de información para la salud a nivel nacional y subnacional a fin de asegurar la disponibilidad de datos de calidad para la toma de decisiones, la formulación de políticas y el monitoreo de las desigualdades en salud, protegiendo al mismo tiempo la confidencialidad y la seguridad de la información de salud personal. (p. 8)

La orientación es explícita: robustecer liderazgo y gestión de datos, promover marcos normativos y asegurar talento humano capaz de ejecutar la transformación digital en todos los niveles de atención. Estas directrices legitiman inversiones en datos de calidad y capas

informativos reutilizables para la decisión clínica y de abastecimiento.

En América Latina, estos desafíos globales y regionales se agravan por factores locales como la fragmentación de sistemas y la dependencia de importaciones, lo que perpetúa brechas en la visibilidad y la interoperabilidad de datos. La problemática de quiebres de stock convive con desafíos estructurales que incluyen fragmentación e interoperabilidad limitadas, asimetrías regulatorias y dependencia de importaciones. Análisis regionales del Banco Interamericano de Desarrollo describen la gran oportunidad de la salud digital para cerrar brechas de calidad, resultados y eficiencia, siempre que se combinen políticas, estándares y capacidades técnicas con enfoque de derechos (Bagolle et al., 2022). Esta perspectiva regional resalta la importancia de desarrollar soluciones tecnológicas contextualmente apropiadas que consideren las particularidades locales.

Los determinantes de quiebres de stock son multifactoriales y abarcan tanto el lado de la oferta como el de la demanda. Del lado de la oferta se identifican fallas de manufactura, escasez de insumos y concentraciones de mercado, mientras que del lado de la demanda se presentan picos estacionales, prácticas de inventario inadecuadas e imprevisibilidad en los patrones de consumo. De hecho, la escasez es un problema global. Al respecto, Shukar et al. (2021) afirman: “Drug shortages are a complex global challenge involving various stakeholders, including manufacturers, regulatory authorities, and healthcare providers” (sección Introduction). En línea con las directrices de la OMS, el acceso a medicamentos básicos sigue siendo insuficiente a escala global, lo que refuerza la pertinencia de fortalecer funciones públicas, supervisión y cooperación interinstitucional.

En Honduras, estas dinámicas latinoamericanas se reflejan en un contexto de digitalización incipiente, donde las brechas en integración y capacidades digitales limitan la respuesta a problemas globales como la escasez persistente. La política sectorial ha dado pasos significativos hacia la mejora de la trazabilidad logística. En 2022, la Secretaría de Salud avanzó en la instalación del Sistema Informático de Administración Logística de Medicamentos e Insumos (SALMI) en hospitales de referencia con el fin de fortalecer el control de inventarios y la disponibilidad (OPS, 2022). Paralelamente, la OPS registró proyectos para fortalecer infraestructura y capacidades, creando condiciones para una mayor visibilidad del abastecimiento (OPS, 2022).

A nivel organizacional, las farmacias privadas enfrentan retos diferenciales respecto del subsector público, incluyendo variabilidad de la demanda, dependencia de proveedores externos, contratos y márgenes, así como la necesidad de integrar fuentes de datos heterogéneas para predecir quiebres y decidir reposiciones. La adopción efectiva de tecnologías digitales depende de factores organizacionales, tecnológicos y humanos, incluyendo capacitación, alineación interna, interoperabilidad y percepción de valor, como sintetiza una revisión sistemática reciente (Nascimento et al., 2023). En consecuencia, el despliegue de paneles visuales y alertas requiere gestión de datos, resguardo de privacidad y alineación con procesos vigentes para evitar fricciones operativas.

En síntesis, los antecedentes globales, regionales y nacionales convergen en tres ideas centrales: la escasez de medicamentos esenciales es persistente y multifactorial; la región cuenta con mandatos y hojas de ruta para fortalecer sistemas de información y aprovechar soluciones digitales con enfoque de derechos; y el contexto hondureño presenta condiciones habilitantes junto con brechas de integración y capacidades que aconsejan intervenciones informacionales acotadas. En consecuencia, para una organización como Farmacias Siman esto justifica un enfoque de soporte a la decisión mediante paneles visuales y alertas que incrementen visibilidad y coordinación, sin alterar los procesos de reposición establecidos.

### **1.3 PLANTEAMIENTO DEL PROBLEMA**

En la sucursal de San Pedro Sula de Farmacias Siman, la gestión del abastecimiento de medicamentos esenciales enfrenta una crisis de eficiencia operativa que impacta directamente en la rentabilidad y el nivel de servicio al paciente. El problema central no es la carencia de herramientas tecnológicas *per se*, sino el alto costo del desabastecimiento y la ineficiencia en la reposición.

Diagnósticos preliminares de la operación sugieren que la farmacia incurre en pérdidas económicas estimadas en US\$9,000 anuales. Para fines de trazabilidad del indicador, esta estimación integra dos componentes medibles: (a) merma por caducidad asociada a sobre-stock y (b) ventas no realizadas atribuibles a quiebres de inventario (*stock-outs*) en medicamentos de alta rotación.

Esta situación es sintomática de una gestión reactiva y empírica. Aunque la farmacia genera diariamente volúmenes constantes de datos de ventas e inventarios, estos se encuentran dispersos en silos de información que impiden una visión integral. Actualmente, las decisiones de reposición se toman basándose en lo que ya ocurrió (“espejo retrovisor”), lo que incrementa el riesgo de quiebres de stock y de sobre-stock con caducidad, al no anticipar la demanda futura con precisión. En consecuencia, el personal depende de la intuición o de promedios simples que no capturan estacionalidad ni tendencias complejas, perpetuando pérdidas por ventas no realizadas y mermas por vencimiento.

La brecha técnica radica en la incapacidad actual de transformar los datos transaccionales históricos en inteligencia preventiva. Existe una desconexión entre la disponibilidad del dato bruto y la toma de decisiones: mientras la operación genera la materia prima (datos), la gerencia carece de los mecanismos analíticos para procesarla y convertirla en alertas tempranas. Esta carencia de información accionable es la causa raíz que perpetúa el ciclo de ineficiencia, impidiendo optimizar los niveles de inventario antes de que ocurra la ruptura o el vencimiento.

En consecuencia, el problema de investigación se define como la persistencia de niveles críticos de incertidumbre en la demanda y pérdidas operativas por la ausencia de un mecanismo analítico que explote la información histórica para optimizar las decisiones de reabastecimiento. Atender esta problemática permitirá transitar de un modelo de "reacción ante el fallo" a uno de "anticipación basada en datos", justificando la necesidad de una solución que blinde la disponibilidad de medicamentos esenciales.

En síntesis, el problema se delimita en la sucursal San Pedro Sula (dónde) y en el abastecimiento de medicamentos esenciales (qué), debido a decisiones de reposición reactivas sin soporte analítico (por qué/cómo), que generan pérdidas por caducidad y ventas no realizadas (qué impacto), en el periodo de análisis definido por los datos históricos disponibles (cuándo), afectando tanto la rentabilidad como el nivel de servicio al paciente (a quién).

## **1.4 PREGUNTAS DEL PROYECTO (FRAMEWORK P.I.C.O.)**

### **1.4.1 PREGUNTA GENERAL**

¿En qué medida un modelo de información con capacidades predictivas (I) para

medicamentos esenciales en Farmacias Siman, sucursal San Pedro Sula (P), comparado con la reposición manual reactiva vigente (C), contribuye a reducir quiebres de stock y pérdidas por caducidad y a mejorar la toma de decisiones mediante tableros y alertas (O), sin intervenir los procesos operativos existentes?

**Delimitación del Caso (Etiquetas del Framework):** Para garantizar la precisión del alcance, se etiquetan los componentes bajo el marco P.I.C.O.:

- **(P) Pacientes/Farmacia:** Gestión de la cadena de suministro de medicamentos esenciales en la sucursal San Pedro Sula de Farmacias Siman.
- **(I) Intervención (Modelo IA):** Desarrollo de un modelo de información con capacidades predictivas.
- **(C) Comparación (Gestión Actual):** Reposición manual y reactiva basada en criterios empíricos.
- **(O) Outcome (Optimización Stock):** Mitigación de quiebres de stock, reducción de pérdidas por caducidad y generación de información para la decisión.
- **Restricción del Estudio:** La evaluación se realiza sin intervenir ni modificar los procesos operativos vigentes.

#### 1.4.2 PREGUNTAS ESPECÍFICAS

1. ¿Cuáles son los requisitos funcionales y no funcionales necesarios para desarrollar un modelo de información con capacidades predictivas de plataforma digital adaptado a las condiciones tecnológicas y operativas de Farmacias Siman?
2. ¿Qué enfoque de inteligencia artificial y técnicas de análisis de datos deben seleccionarse para apoyar la reposición de medicamentos esenciales en el contexto específico de Farmacias Siman y por qué razones técnicas?
3. ¿Cómo debe diseñarse la infraestructura en la nube que soporte el

procesamiento, almacenamiento y visualización de datos, garantizando escalabilidad, disponibilidad y seguridad?

4. ¿Qué indicadores y métricas permiten evaluar la viabilidad técnica del modelo predictivo y la utilidad potencial de tableros (dashboards) y alertas para la toma de decisiones?

## 1.5 OBJETIVOS DEL PROYECTO

### 1.5.1 OBJETIVO GENERAL

Diseñar un modelo de información con capacidades predictivas que apoye la gestión de la cadena de suministro de medicamentos esenciales en Farmacias Siman, generando tableros de control y alertas preventivas para mitigar los quiebres de stock y favorecer el acceso oportuno de los pacientes.

### 1.5.2 OBJETIVOS ESPECÍFICOS

1. Identificar los requisitos funcionales y no funcionales del modelo de información con capacidades predictivas, considerando las condiciones tecnológicas y operativas de Farmacias Siman, así como las limitaciones de procesos y datos disponibles.
2. Definir el enfoque de inteligencia artificial y las técnicas de análisis de datos para apoyar la reposición de medicamentos esenciales en Farmacias Siman, enfocado en información accionable para mitigar quiebres y priorizar reposiciones.
3. Especificar la arquitectura en la nube que sustente la ingesta, el procesamiento, el almacenamiento y la visualización de la información, asegurando criterios de escalabilidad, disponibilidad y seguridad.
4. Validar la viabilidad técnica del modelo predictivo mediante un marco de evaluación que compare su desempeño frente a una línea base reproducible (Naive y Promedio Móvil Simple de 30 días – SMA30), demostrando una mejora  $\geq 30\%$  en MAE (métrica primaria) respecto a la línea base, verificada mediante *backtesting*

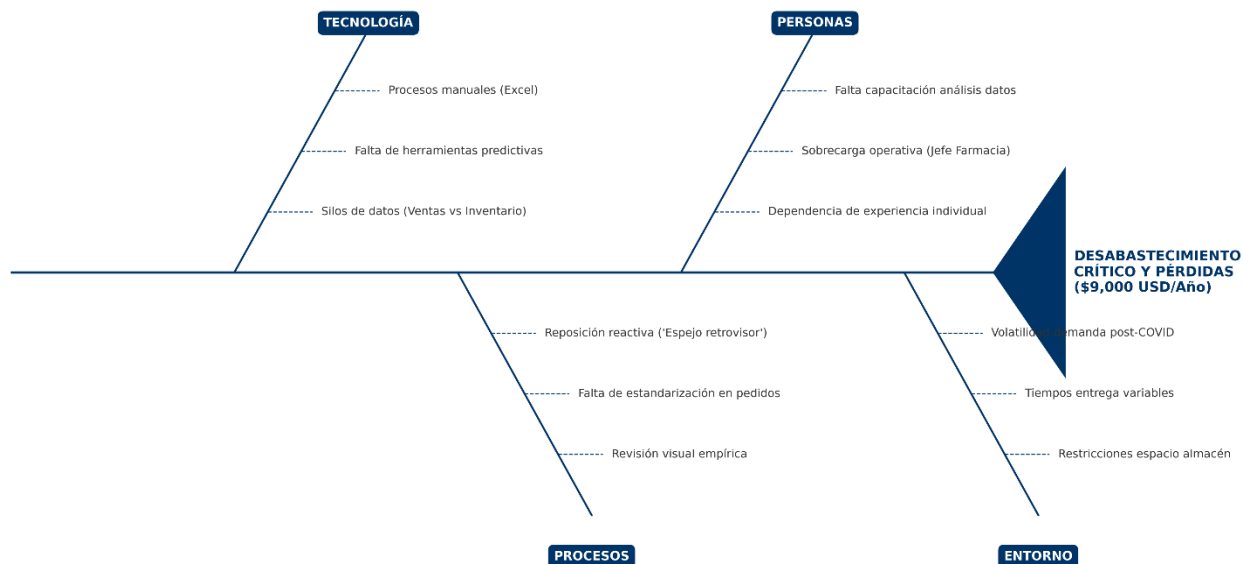
temporal (*walk-forward*), para diciembre de 2025.

## 1.6 JUSTIFICACIÓN

La investigación se justifica por su aporte simultáneo en tres planos: público, institucional y académico. En el plano público, promueve la construcción de una capa informacional confiable y oportuna que facilite la planificación y supervisión de servicios vinculados a medicamentos esenciales, sin reiterar diagnósticos de escasez ni cifras globales. El énfasis recae en cómo transformar datos operativos dispersos en insumos comparables y trazables que permitan decidir, documentar y aprender dentro de una organización privada que interactúa con el ecosistema sanitario. La propuesta se limita a capacidades informacionales (pronósticos, tableros y alertas) que complementen los procesos de reposición vigentes sin sustituirlos ni automatizarlos, reconociendo explícitamente las limitaciones de la operación actual.

Desde el ámbito institucional, el estudio agrega valor al proponer un modelo informacional que genere capacidades analíticas para anticipar patrones de demanda farmacéutica, buscando evidencia sobre su viabilidad en contextos con restricciones de datos y recursos limitados (Badakhshan et al., 2022). La propuesta no busca sustituir sistemas existentes ni alterar los procesos establecidos de reposición, sino generar capacidades informacionales complementarias mediante paneles integrados y alertas predictivas que apoyen las decisiones con supervisión humana continua.

Para profundizar en el análisis de causas raíz del desabastecimiento (efecto), se elaboró un Diagrama de Causa–Efecto (Ishikawa) (ver Ilustración 1), que organiza los factores en Tecnología, Procesos, Personas y Entorno y justifica que la intervención del estudio se limite a una capa informacional (pronóstico, tableros y alertas) sin modificar procesos operativos. Este análisis visual sistematiza cómo la interacción entre brechas tecnológicas (silos de datos), procesos manuales reactivos y factores del entorno contribuye directamente al problema central de desabastecimiento, justificando así la necesidad de una intervención focalizada en la capacidad predictiva.



**Ilustración 1.** Diagrama de Causa-Efecto (Ishikawa) del Desabastecimiento

*Nota.* Elaboración propia. El diagrama identifica las causas raíz clasificadas en Tecnología, Procesos, Personas y Entorno que contribuyen al problema de desabastecimiento.

El enfoque reconoce explícitamente las limitaciones de trabajar con datos históricos acotados y prioriza el desarrollo conceptual sobre la implementación operativa, contribuyendo con un marco metodológico replicable para contextos similares. La evidencia reciente respalda explorar servicios informativos mediante tableros y alertas con capacidades predictivas graduales que prioricen confiabilidad, trazabilidad y cumplimiento antes de la automatización plena. Este enfoque acota riesgos y favorece la adopción en entornos con capacidades heterogéneas, ofreciendo valor incremental sin imponer automatismos. Al-Hourani y Weraikat (2025) identifican en su revisión sistemática centrada en resiliencia de cadenas farmacéuticas la necesidad de mayor confiabilidad, trazabilidad y cumplimiento normativo antes de escalar a operación rutinaria. En este marco, se seleccionará y justificará el enfoque de inteligencia artificial y las técnicas de análisis de datos más adecuadas al contexto de Farmacias Siman, asegurando aplicabilidad operativa y trazabilidad de supuestos.

La viabilidad y oportunidad del proyecto se refuerzan por un entorno regional que reconoce

la necesidad de fortalecer los sistemas de información para la salud, con líneas de acción y actores definidos. Aunque la investigación se desarrolla en un contexto privado, dicho marco proporciona un lenguaje común y expectativas razonables para guiar iniciativas que mejoren la disponibilidad y utilidad de información, sin imponer una ruta tecnológica única. Esta convergencia entre política y práctica habilita proyectos de alcance acotado que documenten condiciones reales de implementación y ofrezcan evidencia de utilidad organizacional. En suma, existe una ventana de oportunidad para probar, evaluar y medir la efectividad informacional de servicios que aporten claridad y estabilidad a la toma de decisiones.

En cuanto a la contribución académica, se propone diseñar y justificar una capa informacional mínima que haga más legible la operación para quienes deciden en el punto de servicio. Ello implica pasar de la retórica de la transformación digital a la operacionalización de requisitos concretos de información y visualizaciones con trazabilidad. De manera deliberada, el estudio no apuesta por promesas causales fuertes ni automatismos; su aporte es documentar supuestos, límites y condiciones para que la información procesada sea pertinente para la decisión táctica. Con ello, contribuye con evidencia reproducible sobre qué prácticas de implementación y uso favorecen el aprovechamiento de datos en organizaciones con recursos y capacidades heterogéneas, en línea con buenas prácticas reconocidas.

En cuanto al impacto esperado, los resultados deberían transparentar criterios de priorización especificando qué producto, por qué y cuándo; fortalecer la rendición de cuentas mediante evidencia verificable de los insumos informacionales utilizados; y habilitar ciclos de mejora continua, comparando decisiones en el tiempo con definiciones estables. Este tipo de valor (claridad, trazabilidad y capacidad de aprendizaje) es coherente con marcos de referencia no prescriptivos que describen resultados deseables sin imponer cómo lograrlos, especialmente útil cuando existen restricciones de recursos y se busca una adopción gradual. En consecuencia, la investigación se plantea como un paso responsable hacia la madurez informacional, con énfasis en prácticas que apuntalan la toma de decisiones sin alterar la operación vigente.

Finalmente, la pertinencia pública se reafirma al vincular la visibilidad informacional con prioridades de salud y con la agenda regional de fortalecimiento de sistemas. Lejos de replicar diagnósticos, el estudio propone criterios y evidencias para decisiones explicables y reproducibles,

donde la información estructurada y una evaluación proporcional de riesgos resultan más determinantes que cualquier promesa de automatización.

## CAPÍTULO II. MARCO TEÓRICO

### 2.1 MACROENTORNO

El macroentorno de la cadena de suministro de medicamentos esenciales se encuentra actualmente configurado por una convergencia de fuerzas globales que condicionan de manera significativa el diseño de nuevos modelos analíticos para la gestión de información en contextos farmacéuticos. No se trata meramente de una evolución tecnológica incremental, sino de una reconfiguración estructural impulsada por la necesidad de resiliencia ante la incertidumbre operativa y sanitaria. Este análisis se estructura en torno a siete vectores globales (Secciones 2.1.2 a 2.1.8) que contextualizan la propuesta tecnológica, complementados por un análisis comparativo PESTEL (Sección 2.1.1) para contrastar la madurez regulatoria local frente a referentes internacionales.

Este análisis del macroentorno internacional no constituye un ejercicio enciclopédico aislado, sino que proporciona los fundamentos conceptuales, técnicos y regulatorios necesarios para justificar las decisiones de arquitectura del modelo predictivo propuesto para Honduras. Se reconoce que, si bien la propuesta tiene un alcance académico acotado, debe cimentarse en las mejores prácticas globales para garantizar su validez técnica, ética y operativa. Como señalan Shukar et al. (2021), la escasez de medicamentos es un "problema global multifactorial" asociado a disrupciones logísticas y fallas de manufactura, lo que exige fortalecer la resiliencia de las cadenas de suministro mediante sistemas de información que permitan transitar de la reacción ante el fallo a la anticipación del riesgo.

#### 2.1.1 ANÁLISIS COMPARATIVO PESTEL (UE, EE. UU., SUDAMÉRICA Y HONDURAS)

Para situar la investigación en el contexto global y justificar la estrategia de diseño del modelo propuesto, resulta imperativo contrastar la madurez regulatoria y tecnológica de Honduras frente a entornos internacionales de referencia. Se realiza un análisis comparativo bajo el marco PESTEL (Político, Económico, Social, Tecnológico, Ecológico y Legal), seleccionando tres zonas geográficas que representan distintos estadios de evolución normativa y de mercado: la Unión Europea (UE) como referente normativo garantista y vinculante; Estados Unidos (EE. UU.) como

referente de innovación tecnológica impulsada por incentivos de mercado; y Sudamérica (específicamente Brasil) como el referente regional (benchmark) más avanzado en la institucionalización de la salud digital.

Este contraste (detallado en la Tabla 1) permite identificar brechas estructurales que el modelo predictivo debe mitigar y fundamenta la adopción voluntaria de estándares internacionales como decisión de gobernanza. En el contexto del caso, la revisión documental sugiere ausencia de un marco transversal equivalente a GDPR/LGPD aplicable de forma integral; por ello, los controles de privacidad, trazabilidad y supervisión deben definirse como requisitos verificables del sistema (OE1–OE3), sin depender exclusivamente de mandatos externos.

**Tabla 1.** *Matriz PESTEL Comparativa para Gobernanza de Datos, IA e Interoperabilidad en Salud Digital*

<b>Dimensión PESTEL</b>	<b>Unión Europea (Referente Normativo)</b>	<b>Estados Unidos (Referente de Innovación)</b>	<b>Sudamérica (Brasil) (Referente Regional)</b>	<b>Honduras (Contexto del Caso)</b>
<b>(P) Político</b>	Estrategia unificada de Mercado Único Digital y adopción vinculante del Reglamento del <b>Espacio Europeo de Datos de Salud (EHDS)</b> para facilitar el intercambio transfronterizo de datos clínicos y secundarios.	Políticas federales agresivas de incentivo a la interoperabilidad ( <i>21st Century Cures Act</i> ) y liderazgo estratégico global en el desarrollo de Inteligencia Artificial como prioridad de seguridad nacional.	Estrategia de Gobierno Digital y Salud Digital institucionalizada mediante la <b>Red Nacional de Datos de Salud (RNDS)</b> , establecida como una política de Estado que trasciende administraciones.	<b>Política Fragmentada:</b> Existen iniciativas aisladas de digitalización gubernamental; sin embargo, en la revisión documental de este estudio no se identificó una Estrategia Nacional de IA o de Salud Digital unificada y vinculante que articule el intercambio de datos con el sector privado farmacéutico.
<b>(E) Económico</b>	Fuerte inversión pública centralizada	Modelo impulsado por el mercado	Inversión estatal sostenida en la	<b>Restricción de Recursos:</b> Baja inversión pública en

	en infraestructura transfronteriza y subsidios directos a la digitalización de los sistemas sanitarios nacionales para reducir la fragmentación.	privado y las aseguradoras, donde los incentivos financieros al desempeño clínico ( <i>Value-Based Care</i> ) traccionan la inversión masiva en tecnología.	plataforma pública <i>Conecte SUS</i> y en la digitalización masiva de servicios ciudadanos para reducir costos operativos y mejorar la cobertura.	infraestructura tecnológica sanitaria. El sector privado (farmacias) debe asumir el costo total de la modernización tecnológica (CAPEX/OPEX) sin subsidios estatales.
<b>(S) Social</b>	Derechos digitales consolidados normativamente; existe una alta conciencia ciudadana sobre la privacidad ("Ciudadanía de Datos") y el derecho al olvido como garantías fundamentales.	Demanda activa de servicios digitales por parte del consumidor empoderado, aunque persisten brechas significativas de equidad en el acceso a la tecnología y la alfabetización digital.	Alta adopción de servicios digitales ciudadanos ( <i>Gov.br</i> ), lo que ha impulsado culturalmente la demanda de transparencia y acceso a datos personales por parte de la población.	<b>Madurez Desigual:</b> Alta penetración de telefonía móvil en la población, pero prácticas de privacidad y ciberseguridad heterogéneas tanto en ciudadanos como en organizaciones, con baja percepción de riesgo.
<b>(T) Tecnológico</b>	Requisitos regulatorios estrictos y marcos comunes que empujan la interoperabilidad obligatoria entre los sistemas de salud de los países miembros de la Unión.	Ecosistema avanzado de <i>Cloud Computing</i> e IA, con una adopción masiva de estándares FHIR impulsada por los mandatos de la ONC ( <i>Office of the National Coordinator</i> ) y la <i>Final Rule</i> .	Interoperabilidad en expansión mediante el estándar HL7 FHIR en la RNDS, buscando la integración efectiva entre los datos del sector público y la red privada de atención.	<b>Heterogeneidad de Sistemas:</b> Predominio de sistemas legados ("islas de información") y baja estandarización en el intercambio de datos, lo que abre una oportunidad para adoptar arquitecturas <i>Cloud</i> modernas por fases.

<p><b>(A)</b> <b>Ambiental</b></p>	<p>El Pacto Verde Europeo exige cadenas de suministro sostenibles, economía circular y la trazabilidad obligatoria de la huella de carbono en la producción farmacéutica.</p>	<p>Enfoque creciente en la eficiencia energética de los centros de datos masivos (Green IT) y en la reducción del desperdicio farmacéutico por vencimiento mediante optimización logística.</p>	<p>Normativas emergentes sobre logística inversa y gestión responsable de residuos de aparatos eléctricos y electrónicos (RAEE) aplicadas al sector salud.</p>	<p><b>Gestión de Mermas:</b> El vencimiento de fármacos es un problema económico y ambiental crítico no optimizado; la normativa de desechos es básica y se centra en la disposición final, no en la prevención.</p>
<p><b>(L) Legal</b></p>	<p><b>GDPR &amp; AI Act:</b> Marcos vinculantes estrictos (Reglamento UE 2016/679 y UE 2024/1689) para la privacidad de datos y la clasificación de riesgo de los sistemas de IA.</p>	<p><b>HIPAA (Vinculante) &amp; NIST (Voluntario):</b> Regulación sectorial fuerte para privacidad en salud y guías de gestión de riesgo técnico (AI RMF) ampliamente adoptadas por la industria.</p>	<p><b>LGPD (Brasil):</b> Ley N° 13.709, moderna y alineada estructuralmente al estándar europeo (GDPR), con una autoridad nacional sancionadora activa.</p>	<p><b>Regulación Limitada:</b> Existe complejidad regulatoria sectorial (sanitaria/comercial) y normativa habilitante (p. ej., firma electrónica); no obstante, para el contexto analizado, la revisión documental no identificó un marco transversal integral equivalente a GDPR/LGPD ni una normativa específica de IA aplicable a decisiones soportadas por modelos. Esta condición traslada la carga de gobernanza y control a la organización.</p>

*Nota.* Elaboración propia basada en fuentes normativas primarias: GDPR (UE, 2016), AI Act (UE, 2024), EHDS (UE, 2025), Cures Act/ONC Final Rule (EE. UU.), HIPAA (EE. UU.), LGPD (Brasil). Para Honduras: revisión documental de normativa sectorial y habilitante identificada en el estudio; el diagnóstico se formula como *hallazgo del caso* (no como afirmación exhaustiva del ordenamiento jurídico).

La comparación detallada en la Tabla 1 revela una asimetría regulatoria para el problema de investigación: (1) en la UE, la gobernanza y clasificación de riesgo de IA se establece por regulación vinculante; (2) en EE. UU., la interoperabilidad se empuja por mandatos y reglas técnicas; (3) en Brasil, existe una ley de protección de datos con autoridad sancionadora; (4) en Honduras, el caso se enfrenta a un marco disperso y no equivalente, por lo que el modelo debe incorporar controles verificables desde el diseño. La revisión documental no identificó un marco integral equivalente a GDPR/LGPD plenamente vigente y aplicado al tratamiento de datos personales en el contexto analizado; aunque existen iniciativas en discusión, la falta de una normativa específica de Inteligencia Artificial traslada la carga de la responsabilidad ética y de gobernanza enteramente a la organización.

Esta realidad tiene una implicación directa y crítica para el diseño de la solución en Farmacias Siman: el modelo no puede depender de la ley local para garantizar su seguridad, eticidad o calidad, porque el marco legal es insuficiente. Por lo tanto, el proyecto debe adoptar un enfoque de cumplimiento voluntario basado en estándares internacionales verificables (específicamente los marcos del NIST), estableciendo tres pilares de diseño no negociables para mitigar el riesgo institucional:

1. **Privacidad por Diseño (Requisito No Funcional):** Implementación técnica de minimización de datos y control de acceso robusto (IAM) para suplir la falta de mandato legal externo, protegiendo la información comercial y del paciente.
2. **Gobernanza del Ciclo de Vida:** Trazabilidad obligatoria de las versiones del modelo predictivo y documentación rigurosa de los supuestos algorítmicos para garantizar la auditoría interna y la reproducibilidad.
3. **Supervisión Humana (Control Operativo):** Configuración de las alertas predictivas estrictamente como herramientas de "apoyo a la decisión" y no como sistemas de "automatización total", mitigando los riesgos éticos y operativos en ausencia de una Ley de IA nacional que delimite responsabilidades.

En coherencia con el Capítulo I, este PESTEL justifica que el diseño del modelo incorpore: (a) requisitos verificables de privacidad/trazabilidad/supervisión (OE1), (b) decisiones

arquitectónicas de seguridad y resiliencia (OE3) y (c) criterios de evaluación que integren desempeño predictivo + utilidad operativa + gobernanza (OE4). En ausencia de mandatos locales equivalentes, se toma como referencia voluntaria NIST CSF 2.0 y NIST AI RMF 1.0.

### 2.1.2 ESCASEZ GLOBAL DE MEDICAMENTOS ESENCIALES

La escasez de medicamentos esenciales no constituye un fenómeno coyuntural o aislado, sino una problemática global sistémica que fundamenta la relevancia y urgencia de desarrollar modelos analíticos especializados. Entre 2020 y 2023, informes del programa de cadena de suministro respaldado por USAID y reportes del The Global Fund documentaron mejoras en disponibilidad cuando se fortalecen plataformas de información y monitoreo logístico que las intervenciones respaldadas por plataformas de información robustas lograron mejorar significativamente la disponibilidad de insumos críticos, protegiendo la continuidad de los tratamientos (Global Health Supply Chain Program-Procurement and Supply Management [GHSC-PSM], 2023; The Global Fund, 2023). Esta evidencia empírica valida la hipótesis subyacente de esta investigación: la tecnología de información, cuando se aplica a la visibilidad de datos, deja de ser un soporte administrativo para convertirse en un determinante clave de la seguridad del paciente.

Los determinantes de esta escasez son complejos y estructurales, incluyendo la concentración geográfica de la producción de principios activos (APIs) y los cuellos de botella logísticos en las rutas de distribución globales. Como respuesta, las autoridades reguladoras avanzadas han transitado desde enfoques reactivos hacia modelos de transparencia y monitoreo activo. En la Unión Europea, la Agencia Europea de Medicamentos (EMA) ha implementado la European Shortages Monitoring Platform (ESMP) para coordinar la detección temprana de faltantes (European Medicines Agency, 2024). La literatura científica y la práctica regulatoria coinciden en un punto: los sistemas de información fortalecidos y los mecanismos de alerta temprana son componentes críticos para mitigar el impacto de los desabastecimientos en la salud pública, permitiendo a los gestores actuar antes de que el producto falte en el estante (European Medicines Agency, 2023).

**Tabla 2.** *Enfoques Internacionales para la Mitigación de la Escasez de Medicamentos Esenciales*

<b>Organización</b>	<b>Política/Iniciativa</b>	<b>Enfoque Principal</b>	<b>Herramientas Tecnológicas</b>
<b>OMS</b>	Lista Modelo de Medicamentos Esenciales 2025	Priorización y acceso universal a tratamientos como derecho humano fundamental.	Sistemas de información sanitaria integrados para la vigilancia epidemiológica y logística.
<b>OPS</b>	Plan de Acción 2024-2030 (IS4H)	Transformación digital regional de los sistemas de salud para mejorar la resiliencia.	Plataformas interoperables basadas en el estándar HL7 FHIR para el intercambio de datos.
<b>FDA</b>	<i>Drug Shortage Database</i>	Transparencia total y monitoreo público de faltantes para informar al mercado.	Base de datos pública de escasez con actualizaciones frecuentes y orientación para actores del mercado.
<b>EMA</b>	<i>Shortage Prevention Initiative</i>	Prevención proactiva de desabastecimientos basada en el análisis de datos de oferta y demanda.	Plataforma regional unificada de notificación y seguimiento (ESMP) para coordinación interestatal.
<b>USAID</b>	<i>Supply Chain Indicators</i>	Medición rigurosa del desempeño logístico mediante Indicadores Clave de Desempeño (KPIs).	Sistemas de monitoreo continuo de indicadores con visualización analítica para la toma de decisiones.

*Nota.* Elaboración propia basada en Organización Mundial de la Salud (2025), Organización Panamericana de la Salud (2024) y documentos regulatorios oficiales (EMA, FDA, USAID). Las herramientas tecnológicas descritas representan las mejores prácticas internacionales aplicables al diseño conceptual del modelo.

### 2.1.3 TRANSFORMACIÓN DIGITAL EN CADENAS FARMACÉUTICAS

La digitalización de las cadenas farmacéuticas se ha consolidado como un imperativo estratégico de sostenibilidad operativa. Las plataformas analíticas y de inteligencia artificial

requieren, no obstante, una infraestructura subyacente escalable y segura que soporte el procesamiento de grandes volúmenes de datos. Este soporte tecnológico debe ser consistente con marcos de referencia modernos, como el *NIST Cybersecurity Framework* (CSF 2.0) y el *AI Risk Management Framework* (AI RMF 1.0), que orientan las capacidades técnicas y organizacionales necesarias para operar servicios críticos en entornos digitales hostiles.

La integración de la Inteligencia Artificial en operaciones farmacéuticas ha demostrado impactos documentados y cuantificables en la literatura científica reciente. La literatura reporta que la analítica predictiva puede capturar patrones no lineales de demanda y apoyar decisiones de inventario; sin embargo, la magnitud de mejora depende del contexto, la calidad de datos y el diseño de validación temporal (Fourkiotis & Tsadiras, 2023; Badakhshan et al., 2022). Estudios recientes, como los de Badakhshan et al. (2022), proporcionan evidencia empírica sobre la efectividad de combinar simulación y aprendizaje automático, reportando mejoras tangibles en métricas operacionales de disponibilidad y reducción de costos operativos. Esta evidencia valida la viabilidad técnica de adoptar enfoques híbridos en contextos farmacéuticos, siempre manteniendo la premisa de que la IA es una herramienta de soporte y la supervisión humana es obligatoria para las decisiones finales.

**Tabla 3.** *Evidencia Internacional de Aplicación de Tecnologías Digitales en Cadenas Farmacéuticas*

<b>Aplicación Tecnológica</b>	<b>Problema Abordado</b>	<b>Tecnología Principal</b>	<b>Contexto de Aplicación</b>	<b>Mejora Documentada</b>
<b>Analítica Predictiva de Demanda</b>	Información limitada e incertidumbre sobre patrones de consumo futuros.	Aprendizaje automático especializado ( <i>Machine Learning</i> ).	Cadenas farmacéuticas internacionales y distribución.	Mejoras significativas y cuantificables en las métricas de exactitud predictiva ( <i>forecast accuracy</i> ).
<b>Tableros Integrados</b>	Visibilidad informacional fragmentada en silos	<i>Business Intelligence</i> + <i>Cloud Computing</i> .	Farmacias multi-sucursal y redes minoristas	Integración efectiva de múltiples fuentes de datos heterogéneas para la toma

	de datos aislados.		dispersas.	de decisiones centralizada.
<b>Sistemas de Alerta Temprana</b>	Detección tardía de riesgos operativos y quiebres de stock inminentes.	Procesamiento de eventos complejos en tiempo real.	Gestión de inventarios críticos y productos perecederos.	Generación documentada de alertas tempranas que permiten acciones correctivas preventivas.
<b>Arquitecturas Escalables</b>	Limitaciones rígidas y altos costos de la infraestructura tradicional ( <i>on-premise</i> ).	Computación en la nube ( <i>Cloud Computing</i> ).	Organizaciones en proceso de transformación digital.	Mejora en la disponibilidad, elasticidad y resiliencia de los servicios de información críticos.

*Nota.* Evidencia sintetizada de estudios recientes sobre analítica predictiva en cadenas farmacéuticas. Elaboración propia basada en Al-Hourani y Weraikat (2025) y Badakhshan et al. (2022).

#### 2.1.4 INTEROPERABILIDAD Y GESTIÓN DE DATOS EN SALUD

La interoperabilidad técnica y semántica es una condición sine qua non para integrar datos provenientes de sistemas heterogéneos y evitar la creación de nuevos silos de información. En este ámbito, el estándar HL7 FHIR (*Fast Healthcare Interoperability Resources*) se ha consolidado como el marco dominante global para el intercambio de datos sanitarios (Health Level Seven International [HL7], 2023). Para la gestión logística y de cadena de suministro, la especificación FHIR ofrece recursos específicos como *SupplyRequest* y *SupplyDelivery*, expuestos mediante APIs RESTful modernas, lo que facilita una interoperabilidad incremental, modular y menos costosa que los estándares antiguos basados en mensajería compleja.

La Organización Panamericana de la Salud (2024), en su Plan de Acción regional, establece explícitamente que "se debe garantizar la interoperabilidad de los sistemas de información para la salud" (p. 8), posicionando al estándar HL7 FHIR como la arquitectura de referencia para la región de las Américas. Complementariamente, los estándares terminológicos son críticos para asegurar la interoperabilidad semántica (que el dato signifique lo mismo para todos los actores): SNOMED CT proporciona la terminología clínica necesaria para describir condiciones y tratamientos, mientras que la Clasificación Anatómica Terapéutica Química (ATC) de la OMS permite

comparaciones farmacológicas robustas a nivel internacional. Asimismo, los estándares GS1 para la identificación única de productos aseguran la trazabilidad física a lo largo de la cadena, cerrando el ciclo entre el dato digital y el producto físico.

### 2.1.5 ÉTICA, GOBERNANZA DE IA Y CIBERSEGURIDAD EN SALUD

La integración de algoritmos de inteligencia artificial en sistemas de salud introduce riesgos éticos multidimensionales que no pueden ser ignorados ni gestionados únicamente con controles técnicos. Los principios éticos han evolucionado desde directrices aspiracionales abstractas hacia marcos operacionales concretos y auditables. La OMS (2021) definió los principios rectores para el uso responsable de la IA en salud, abordando dimensiones críticas como la transparencia, la equidad y la responsabilidad.

Sin embargo, para operacionalizar estos principios en un proyecto técnico, el NIST AI Risk Management Framework (AI RMF 1.0) se presenta como la guía más robusta y aplicable. Este marco voluntario organiza la gestión de riesgos en cuatro funciones núcleo: Govern (Gobernar), Map (Mapear), Measure (Medir) y Manage (Gestionar). El National Institute of Standards and Technology (2023) caracteriza la IA confiable como aquella que es válida y robusta, segura y resiliente, con rendición de cuentas, transparencia, explicabilidad, privacidad y gestión de sesgos como atributos verificables:

Trustworthy AI systems are valid and reliable, safe, secure and resilient, accountable and transparent, explainable and interpretable, privacy-enhanced, and fair with their harmful bias managed. (p. 12)

**Tabla 4.** Principios Éticos para IA en Salud y su Relevancia para Plataformas Farmacéuticas

Principio Ético	Definición Operacional	Implicaciones de Diseño del Modelo	Consideraciones de Implementación
<b>Transparencia</b>	Capacidad de explicar cómo y por qué el algoritmo llegó a una	Interfaces de usuario que visualicen los factores contribuyentes de la	Inclusión de métricas de importancia de variables ( <i>feature importance</i> ) en los tableros para el

	decisión específica.	predicción.	usuario final.
<b>Equidad</b>	Rendimiento del modelo consistente y sin sesgos a través de diferentes grupos o categorías.	Validación balanceada del modelo por subgrupos terapéuticos y tipos de producto.	Pruebas exhaustivas con conjuntos diversos de medicamentos para evitar sesgos algorítmicos.
<b>Responsabilidad</b>	Definición clara de la cadena de responsabilidad humana sobre las decisiones asistidas por IA.	Estructuras de gobernanza documentadas y roles definidos para la operación del sistema.	Procedimientos claros de escalamiento y supervisión humana obligatoria para decisiones críticas.
<b>Privacidad</b>	Protección rigurosa de datos comerciales y sanitarios sensibles contra accesos no autorizados.	Cifrado en tránsito/reposo, control de acceso basado en roles (RBAC) y minimización de datos.	Evaluaciones proporcionales de impacto en privacidad y controles de acceso (según alcance del caso), documentadas como evidencia de gobernanza.
<b>Supervisión Humana</b>	Garantía de control humano significativo sobre las decisiones críticas del sistema.	Flujos de trabajo diseñados para que la decisión final de compra/reposición sea siempre humana.	Capacidades técnicas para que el operador pueda anular o corregir las sugerencias del algoritmo.
<b>Ciberseguridad</b>	Protección activa del sistema contra amenazas, ataques y vulnerabilidades técnicas.	Enfoque de "Seguridad por Diseño" alineado al NIST CSF y detección de anomalías.	Monitoreo continuo de la infraestructura y gestión proactiva de parches de seguridad.

*Nota.* Elaboración propia basada en los estándares del National Institute of Standards and Technology (2023). Estos principios constituyen los requisitos no funcionales éticos del sistema.

## 2.1.6 IMPACTO DE DISRUPCIONES GLOBALES EN CADENAS FARMACÉUTICAS

Las disrupciones globales recientes, con la pandemia de COVID-19 como evento

paradigmático, han funcionado como una prueba de estrés masiva para las cadenas de suministro farmacéuticas, revelando vulnerabilidades sistémicas profundas que habían permanecido latentes. Estas disrupciones expusieron la fragilidad inherente de los modelos logísticos basados exclusivamente en la eficiencia extrema (Just-in-Time) sin redundancia ni visibilidad de datos.

En el ámbito europeo, la respuesta ha sido tanto regulatoria como tecnológica: la EMA ha impulsado instrumentos como la plataforma ESMP para prevenir y mitigar faltantes, subrayando la importancia crítica de la transparencia y el reporte oportuno de datos de inventario (European Medicines Agency, 2023). El análisis de las respuestas organizacionales exitosas durante la crisis revela un patrón consistente: aquellas organizaciones que contaban con sistemas de información integrados y capacidades predictivas pudieron adaptarse más rápidamente a la volatilidad de la demanda y la oferta. La transformación digital post-pandemia, por tanto, no es opcional; prioriza sistemas que generen información accionable sobre riesgos emergentes, validando la relevancia de modelos que transformen datos operativos fragmentados en inteligencia para la toma de decisiones bajo incertidumbre (Shukar et al., 2021).

**Tabla 5.** *Disrupciones Globales y Respuestas Documentadas en Cadenas Farmacéuticas*

<b>Tipo de Disrupción</b>	<b>Impacto Documentado</b>	<b>Respuesta Tecnológica</b>	<b>Fuente de Evidencia</b>
<b>Pandemia COVID-19 (2020-2022)</b>	Exposición de vulnerabilidades sistémicas, ruptura de cadenas de suministro y picos de demanda.	Fortalecimiento acelerado de sistemas de información, telemetría y adopción de canales digitales.	European Medicines Agency (2023)
<b>Interrupciones Logísticas</b>	Escasez crítica de medicamentos esenciales por fallas en transporte global y producción.	Adopción de mejores prácticas de prevención, diversificación de proveedores y monitoreo de rutas.	Shukar et al. (2021)
<b>Rigideces Regulatorias</b>	Capacidad limitada para monitorear inventarios y demanda en tiempo real durante emergencias.	Implementación de plataformas de notificación automatizada y digitalización de trámites regulatorios.	European Medicines Agency (2023)

*Nota.* Elaboración propia basada en la documentación oficial sobre causas de escasez y estrategias de mitigación (European Medicines Agency, 2023; Shukar et al., 2021).

### 2.1.7 CONVERGENCIA TECNOLÓGICA Y ECOSISTEMAS DIGITALES EMERGENTES

El contexto tecnológico actual está marcado por la convergencia sinérgica de tecnologías que anteriormente operaban de forma aislada: Cloud Computing, Inteligencia Artificial y Big Data. Esta convergencia crea ecosistemas digitales integrados que transforman radicalmente las capacidades de gestión disponibles para las organizaciones. Mell y Grance (2011), en su definición seminal para el NIST, describen la computación en la nube como un modelo que permite el acceso ubicuo, conveniente y bajo demanda a un conjunto compartido de recursos informáticos configurables.

Esta característica es fundamental para el sector farmacéutico en economías emergentes como Honduras, ya que habilita el acceso a capacidades analíticas avanzadas (que requieren gran poder de cómputo para el entrenamiento de modelos) sin la necesidad de inversiones prohibitivas en infraestructura física (CAPEX). Al trasladar el costo a un modelo operativo flexible basado en el consumo (OPEX), la nube democratiza el acceso a la tecnología predictiva. La maduración de estos ecosistemas permite a organizaciones medianas, como Farmacias Siman, desplegar soluciones sofisticadas de predicción de demanda que, hace una década, solo estaban al alcance de grandes corporaciones globales con centros de datos propios.

### 2.1.8 MODELOS OPERATIVOS Y GESTIÓN DEL SERVICIO PARA PLATAFORMAS FARMACÉUTICAS

Finalmente, el éxito sostenible de una plataforma digital no depende solo de la excelencia tecnológica, sino del modelo operativo y de gobierno que la sustenta. Es necesario establecer un andamiaje robusto que asegure la creación de valor continua y la estabilidad del servicio. Marcos de gestión consolidados como ITIL 4 enfatizan la "co-creación de valor" entre el proveedor de TI y el negocio (Axelos, 2019), una perspectiva esencial para alinear los tableros analíticos con las necesidades reales de los farmacéuticos en el punto de venta.

Para la gestión de riesgos tecnológicos y de inteligencia artificial, este estudio adopta los

marcos del NIST como referencia técnica principal, dado su enfoque pragmático y basado en riesgos:

### 2.1.8.1 NIST CSF 2.0

El NIST Cybersecurity Framework (CSF) 2.0 se ha consolidado como el estándar de facto para la gestión de ciberseguridad a nivel global. Organiza sus funciones núcleo en: GOVERN, IDENTIFY, PROTECT, DETECT, RESPOND y RECOVER. La reciente incorporación de la función GOVERN en la versión 2.0 subraya que la ciberseguridad es una responsabilidad estratégica de gobierno corporativo, y no solo un problema técnico del departamento de TI (National Institute of Standards and Technology, 2024).



**Ilustración 2.** NIST CSF 2.0 — Estructura del Core y Funciones

*Nota.* Adaptado de The NIST Cybersecurity Framework (CSF) 2.0 (NIST.CSWP.29), por National Institute of Standards and Technology, 2024 (<https://doi.org/10.6028/NIST.CSWP.29>). Dominio público.

Esta evolución resulta fundamental para la especificación de la arquitectura en nube contemplada en el tercer objetivo específico del proyecto, donde la seguridad y gestión de datos constituyen criterios esenciales. El NIST CSF 2.0, de alcance intersectorial, amplía su marco con la función GOVERN y es aplicable a organizaciones de todos los sectores y tamaños; resulta

especialmente útil para el sector salud donde es fundamental gestionar riesgos y fortalecer la resiliencia de servicios digitales críticos.

#### 2.1.8.2 NIST AI RMF 1.0

De forma análoga, el *NIST AI Risk Management Framework* proporciona la estructura necesaria para gestionar los riesgos específicos y únicos de la Inteligencia Artificial, promoviendo el desarrollo de sistemas que sean explicables, justos y seguros. Su adopción en este proyecto garantiza que el modelo predictivo se diseñe desde el inicio ("Security by Design") considerando los riesgos de sesgo algorítmico y confiabilidad, aspectos críticos en el sector salud (National Institute of Standards and Technology, 2023).



**Ilustración 3.** *NIST AI RMF 1.0 — Funciones del Core (Govern, Map, Measure, Manage)*

*Nota.* Adaptado de Artificial Intelligence Risk Management Framework (AI RMF 1.0) (NIST.AI.100-1), por National Institute of Standards and Technology, 2023 (<https://doi.org/10.6028/NIST.AI.100-1>). Dominio público.

En conclusión, los siete vectores globales analizados en esta sección (escasez, transformación digital, interoperabilidad, ética, disrupciones, convergencia y modelos operativos) no operan como fenómenos aislados; interactúan para formar el marco conceptual internacional que fundamenta, valida y guía el diseño del modelo de información propuesto. La siguiente sección descenderá de este análisis global para examinar cómo estas tendencias se manifiestan, friccionan

y adaptan en el contexto específico del microentorno hondureño.

## 2.2 MICROENTORNO

Tras analizar las tendencias globales en el macroentorno, esta sección profundiza en las condiciones operativas y competitivas específicas de Honduras que delimitan el campo de acción para el modelo predictivo en Farmacias Siman. Mientras el análisis macro identificó la necesidad de gobernanza y estándares, el microentorno revela las fricciones inmediatas: una intensidad competitiva regional que presiona los márgenes y una cadena de suministro local caracterizada por la incertidumbre. La justificación de la intervención tecnológica no reside únicamente en la modernización, sino en la necesidad de supervivencia operativa ante un entorno donde la disponibilidad del producto es el principal diferenciador sostenible (Porter, 2008).

### 2.2.1 ANÁLISIS DE COMPETITIVIDAD REGIONAL (MODELO DE LAS 5 FUERZAS)

Para dimensionar la presión competitiva, se aplica el modelo de las 5 Fuerzas de Porter (1979, actualizado 2008) al sector retail farmacéutico centroamericano. Este análisis comparativo es una caracterización cualitativa (no econométrica) orientada a derivar implicaciones de diseño para el caso hondureño. En particular, cuando (i) el poder del comprador es alto y (ii) el poder del proveedor es alto, la disponibilidad se vuelve el principal diferenciador y exige: (a) pronóstico con validación temporal, (b) reglas de alerta condicionadas a lead time y mínimos de compra, y (c) trazabilidad de decisiones. El detalle comparativo se presenta en la Tabla 6.

**Tabla 6.** *Análisis comparativo de las 5 Fuerzas de Porter en Centroamérica (Retail Farmacéutico)*

<b>Fuerza de Porter</b>	<b>Costa Rica (Mercado Maduro)</b>	<b>Panamá (Ventaja Logística)</b>	<b>El Salvador (Competencia Agresiva)</b>	<b>Honduras (Contexto Siman)</b>
<b>(1) Rivalidad entre Competidores</b>	<b>Moderada-Alta:</b> Mercado consolidado con	<b>Moderada:</b> Rivalidad segmentada entre	<b>Muy Alta:</b> Guerra de precios agresiva liderada por cadenas	<b>Alta y Fragmentada:</b> Coexistencia entre cadenas de gran escala

	<p>cadenas dominantes (ej. <i>Fischel, La Bomba</i>) que compiten mediante programas de lealtad robustos y servicios de valor agregado.</p>	<p>grandes cadenas (ej. <i>Farmacias Arrocha</i>) y farmacias independientes; la competencia se enfoca en la profundidad del surtido.</p>	<p>de descuento (ej. <i>Farmacias Económicas</i>) y una alta densidad de puntos de venta por habitante.</p>	<p>(p. ej., Kielsa) y formatos de descuento (p. ej., Punto Farma, FarmaValue, Punto Max), con competencia centrada en precio y disponibilidad inmediata.</p>
<p><b>(2) Poder de Negociación de los Proveedores</b></p>	<p><b>Bajo-Medio:</b> Las cadenas poseen escala para negociar. Además, la Caja Costarricense de Seguro Social (CCSS) absorbe gran parte de la demanda de crónicos, reduciendo la presión sobre el retail.</p>	<p><b>Bajo:</b> La <b>Zona Libre de Colón (ZLC)</b> actúa como <i>hub</i> logístico, facilitando el acceso directo a distribuidores globales y reduciendo tiempos de reposición.</p>	<p><b>Medio:</b> Dependencia de distribuidores regionales, pero con múltiples opciones de abastecimiento debido a la integración comercial y cercanía logística.</p>	<p><b>Alto:</b> Dependencia de un número limitado de distribuidores mayoristas y condiciones comerciales que pueden restringir crédito y disponibilidad; en el caso observado, los tiempos de entrega se reportan como variables, lo que incrementa la incertidumbre operativa.</p>
<p><b>(3) Amenaza de Nuevos Entrantes</b></p>	<p><b>Baja:</b> Altas barreras regulatorias (Ministerio de Salud) y costos operativos elevados desincentivan la entrada de competidores informales.</p>	<p><b>Media:</b> Barreras logísticas bajas, aunque los altos costos inmobiliarios en zonas urbanas actúan como filtro de entrada financiero.</p>	<p><b>Alta:</b> Bajas barreras de entrada para farmacias independientes, lo que satura el mercado informal y de conveniencia.</p>	<p><b>Media-Alta:</b> Las barreras tecnológicas son bajas, facilitando la apertura; sin embargo, el capital de trabajo (inventario) constituye la barrera real de sostenibilidad.</p>

<b>(4) Poder de los Compradores</b>	<b>Medio:</b> Consumidor con cobertura de seguridad social universal que valora la farmacia privada por agilidad y servicio, no solo por necesidad.	<b>Alto:</b> Consumidor con mayor poder adquisitivo relativo que exige variedad de marcas premium, dermocosmética y experiencia de compra integral.	<b>Muy Alto:</b> Alta sensibilidad al precio; el cliente rota entre farmacias buscando diferencias mínimas de costo debido a la oferta masiva.	<b>Muy Alto:</b> Extrema sensibilidad al precio y a la disponibilidad inmediata; ante un quiebre de stock, el costo de cambio ( <i>switching cost</i> ) es nulo para el paciente.
<b>(5) Amenaza de Productos Sustitutos</b>	<b>Baja:</b> Fuerte cultura de prescripción médica y preferencia por marcas éticas respaldada por la regulación sanitaria.	<b>Media:</b> Mercado abierto a suplementos nutricionales y medicina alternativa de alta gama como complementos terapéuticos.	<b>Alta:</b> Alta prevalencia de genéricos intercambiables y venta libre sin receta, fomentada por políticas de acceso.	<b>Alta:</b> Proliferación de genéricos intercambiables y venta libre, utilizados frecuentemente como alternativa ante el desabastecimiento de marcas prescritas.

*Nota.* Elaboración propia. Caracterización basada en la observación directa de la oferta comercial y propuestas de valor públicas (sitios web corporativos y reportes de mercado, recuperados en 2024). Los nombres se utilizan como referentes ilustrativos de arquetipos competitivos.

La comparativa regional revela que Farmacias Siman opera en lo que Porter (2008) describiría como un entorno de "rentabilidad restringida". A diferencia de sus pares en Panamá, que se benefician de eficiencias logísticas estructurales derivadas de la Zona Libre de Colón, o de Costa Rica, donde el mercado premia la calidad del servicio, la operación hondureña enfrenta la convergencia de un alto poder de proveedores y una demanda extremadamente elástica al precio y la disponibilidad. En este escenario, la disponibilidad del producto deja de ser una métrica operativa para convertirse en la variable estratégica crítica: lo que justifica (i) pronóstico con validación temporal para anticipar demanda, y (ii) alertas operativas configuradas por lead time y stock de seguridad, para actuar antes del quiebre.

## 2.2.2 ANÁLISIS COMPETITIVO: SIMAN FRENTE A REFERENTES LOCALES Y REGIONALES

Para profundizar en la dinámica de rivalidad identificada en el modelo de Porter, se analiza el posicionamiento de Farmacias Siman frente a dos arquetipos de competidores que definen el mercado hondureño. Atendiendo a la necesidad de contrastar modelos de negocio, se incorpora el análisis del formato regional de descuento.

1. **Líderes de Escala (Referente Local: Kielsa):** Representan el dominio por capilaridad. Su estrategia se basa en la omnipresencia física y el poder de compra masivo, lo que les permite diluir costos fijos y presionar márgenes.
2. **Formatos de Descuento (Referente Regional: FarmaValue / Local: Punto Farma):** Representan la competencia por precio. *FarmaValue*, como referente regional, ha estandarizado una propuesta de valor explícita basada en una oferta centrada en precio y disponibilidad, educando al consumidor para exigir descuentos agresivos.

**Tabla 7.** *Matriz de Posicionamiento Competitivo (Siman vs. Arquetipos de Mercado)*

<b>Dimensión Estratégica</b>	<b>Farmacias Siman (Caso de Estudio)</b>	<b>Líder de Escala Local (Ref: Kielsa)</b>	<b>Descuento Regional (Ref: FarmaValue)</b>
<b>Estrategia Genérica</b>	Diferenciación enfocada en Servicio y Disponibilidad de Éticos.	Liderazgo en Costos por volumen y Cobertura Geográfica.	<b>Liderazgo en Costos:</b> Enfoque agresivo en precio bajo y alta rotación.
<b>Fortaleza Clave</b>	Atención farmacéutica personalizada y confianza del paciente recurrente.	Poder de negociación con laboratorios y economías de escala nacional.	Red multinacional y eficiencia operativa diseñada para sostener márgenes reducidos.
<b>Debilidad Crítica</b>	<b>Gestión de Inventarios Reactiva:</b> Alta exposición a quiebres en productos críticos de menor rotación.	Servicio impersonal y estandarizado; experiencia transaccional.	Percepción de servicio limitado en asesoría; enfoque en despacho rápido.

<b>Riesgo Principal</b>	Erosión de la base de clientes por <b>Stock-out</b> (falta de producto).	Canibalización entre puntos de venta propios y saturación.	Guerra de precios insostenible ante fluctuaciones de costos de proveedores.
<b>Oportunidad Analítica</b>	<b>Excelencia en Disponibilidad:</b> Utilizar IA para asegurar el stock que fideliza, evitando competir por precio.	Optimización logística de su propia red de distribución.	Analítica descriptiva para sostener las promesas de precio a escala regional.

*Nota.* Caracterización basada en la observación directa de la oferta comercial y propuestas de valor públicas de los competidores mencionados (Grupo Farsimán, s. f.; FarmaValue, s. f.). Los nombres se utilizan como referentes ilustrativos de arquetipos competitivos.

Ante la agresividad de precios de formatos regionales como *FarmaValue* y la cobertura territorial de líderes como *Kielsen*, Farmacias Siman se encuentra en una posición donde competir por precio es financieramente inviable y competir por cobertura requiere inversiones de capital prohibitivas. Por consiguiente, la estrategia viable es la Diferenciación por Disponibilidad. El modelo predictivo propuesto en esta investigación no es meramente una herramienta técnica, sino una respuesta estratégica para garantizar la continuidad de los tratamientos, capturando al segmento de pacientes que valora la confiabilidad sobre el descuento marginal (Waller & Fawcett, 2013).

### 2.2.3 ESTADO DE LA CADENA DE SUMINISTRO FARMACÉUTICO EN HONDURAS

La viabilidad de la estrategia de disponibilidad depende intrínsecamente de las condiciones de la cadena de suministro local. En Honduras, este eslabón atraviesa una etapa de transición crítica, caracterizada por la coexistencia de prácticas logísticas tradicionales y fragmentadas con iniciativas emergentes de digitalización.

Persisten brechas significativas de desempeño logístico, documentadas por organismos internacionales. El *Global Health Supply Chain Program* (GHSC-PSM, 2024) señala que la visibilidad limitada de datos y la variabilidad en los tiempos de entrega (reportada entre 24 y 72 horas para farmacias independientes según GHSC-PSM, 2024) impactan directamente la

disponibilidad de medicamentos esenciales al consumidor final. En el sector público, la Secretaría de Salud ha respondido extendiendo el Sistema Informático de Administración Logística de Medicamentos e Insumos (SALMI) en establecimientos de referencia, apoyada por la Organización Panamericana de la Salud (OPS, 2022).

Si bien la integración técnica entre los sistemas públicos (SALMI) y el sector privado es aún incipiente, la tendencia hacia la digitalización sugiere que el intercambio de información agregada podría habilitarse en el mediano plazo, siempre que se definan estándares de interoperabilidad y gobernanza de datos. La literatura especializada respalda esta dirección: Mwencha et al. (2017) demuestran que la adopción de sistemas electrónicos de gestión logística (*eLMIS*) se correlaciona positivamente con la mejora en la disponibilidad de medicamentos y la reducción de desperdicios.

**Tabla 8.** *Brechas del Ecosistema Farmacéutico Hondureño y Oportunidades Analíticas*

<b>Dimensión Operativa</b>	<b>Estado Actual (Observación del Caso)</b>	<b>Tendencia Proyectada (Escenario)</b>	<b>Oportunidad para Modelos Analíticos</b>
<b>Monitoreo de Inventarios</b>	Fragmentado; actualización manual con desfases de tiempo.	Integración gradual mediante sistemas digitales en tiempo real.	Desarrollo de capacidades predictivas para compensar la latencia de datos.
<b>Seguimiento de Pedidos</b>	Limitado a confirmación básica (teléfono/correo); reactivo.	Trazabilidad integral con capacidades de anticipación de fallas.	Algoritmos de detección temprana de interrupciones en el suministro.
<b>Integración de Datos</b>	Silos operativos sin interoperabilidad estándar entre actores.	Plataformas unificadas bajo estándares (ej. HL7 FHIR).	Arquitecturas de consolidación de datos heterogéneos.
<b>Analítica Predictiva</b>	Limitada a cálculos de promedios históricos (revisión visual).	Implementación gradual de <i>Machine Learning</i> .	Modelos especializados (ej. <i>Gradient Boosting</i> ) para contextos de datos limitados.

*Nota.* Elaboración propia basada en el diagnóstico del caso y tendencias documentadas por GHSC-PSM (2024).

## 2.2.4 HOJA DE RUTA DE TRANSFORMACIÓN DIGITAL EN SALUD EN HONDURAS

El contexto tecnológico en el que opera Farmacias Siman no es estático. La transformación digital del sector salud en Honduras se enmarca formalmente en la Hoja de Ruta de Transformación Digital y el Plan de Acción IS4H 2024-2030 (Secretaría de Salud, 2024; OPS, 2024). Esta visión gubernamental configura el marco operativo futuro, estableciendo oportunidades de alineación técnica para el sector privado.

La coordinación estratégica entre iniciativas públicas y privadas emerge como un factor crítico de éxito. Para organizaciones privadas, esto implica la adopción voluntaria de mejores prácticas de estandarización técnica (como la catalogación estandarizada de medicamentos) y la alineación con protocolos nacionales de reporte. Esta alineación proactiva no solo reduce fricciones de cumplimiento regulatorio futuro, sino que facilita la interoperabilidad técnica necesaria para nutrir modelos analíticos con datos del entorno (Bagolle et al., 2022).

## 2.2.5 MARCOS ESTRATÉGICOS IS4H EN HONDURAS

La Secretaría de Salud (2024) ha tomado como referencia los niveles del modelo de madurez de Sistemas de Información para la Salud (IS4H) propuesto por la OPS (2017) para evaluar y guiar la evolución de la gestión informacional en el país. Entender este modelo es vital para situar la madurez tecnológica actual de Farmacias Siman.

**Tabla 9.** *Niveles de Implementación IS4H en Honduras y su Impacto en el Sector Privado*

<b>Nivel de Madurez</b>	<b>Característica Principal</b>	<b>Estado Conceptual (2024)</b>	<b>Impacto Potencial (Sector Privado)</b>
<b>1. Básico</b>	Sistemas fragmentados y manuales.	Presencia dominante de silos operativos y registros en papel.	Integración logística inicial y digitalización de inventarios base.

<b>2. Reactivo</b>	Datos disponibles, pero no integrados.	Estandarización incipiente de catálogos y reportes.	Consolidación de reportes manuales para cumplimiento regulatorio.
<b>3. Proactivo</b>	Información utilizada para la decisión.	Pilotos de digitalización y uso de analítica descriptiva.	<b>Desarrollo de capacidades de predicción y alertas automatizadas.</b>
<b>4. Gestionado</b>	Interoperabilidad técnica y semántica.	En desarrollo normativo y definición de estándares.	Colaboración sectorial y acceso a datos vía estándares seguros.
<b>5. Optimizado</b>	Mejora continua basada en datos.	Escenario futuro deseable.	Participación en plataformas integradas de salud nacional.

*Nota.* Adaptación conceptual basada en el Modelo de Madurez IS4H (OPS, 2017).

## 2.2.6 SISTEMAS DE INFORMACIÓN PARA LA SALUD EN HONDURAS

El ecosistema de información en Honduras integra diversas plataformas especializadas bajo diferentes instituciones rectoras. Aunque operan independientemente, estas plataformas constituyen fuentes potenciales de datos externos para enriquecer los modelos predictivos corporativos. La Tabla 10 sintetiza los sistemas operativos principales.

**Tabla 10.** *Sistemas de Información Farmacéutica y Sanitaria en Honduras*

<b>Sistema/Plataforma</b>	<b>Institución Responsable</b>	<b>Funcionalidad Principal</b>	<b>Oportunidades para el Sector Privado</b>
<b>SALMI</b>	Secretaría de Salud	Gestión logística de medicamentos en la red pública.	Referencia de estándares técnicos y catálogos de medicamentos.
<b>Noti-FACEDRA</b>	ARSA / COMISCA	Monitoreo regional de farmacovigilancia y reacciones adversas.	Integración para la notificación digital de reacciones adversas (RAM).
<b>Portal de Registro Sanitario</b>	ARSA	Trazabilidad y legalidad de productos farmacéuticos.	Consultas en línea para validar proveedores y registros vigentes.

<b>Honducompras (SICC)</b>	ONCAE	Portal de transparencia en contratación pública.	Inteligencia de mercado (precios referenciales de licitaciones).
<b>Sistema Epidemiológico</b>	SESAL	Vigilancia de enfermedades y brotes.	Acceso a boletines epidemiológicos para ajustar pronósticos de demanda.

*Nota.* Elaboración propia basada en documentación pública de la Agencia de Regulación Sanitaria (ARSA, 2024) y la Oficina Normativa de Contratación y Adquisiciones del Estado (ONCAE, 2025).

La integración con estas plataformas presenta oportunidades mediante mecanismos de intercambio de información (como portales web o archivos planos estructurados) que faciliten el acceso a datos regulatorios y epidemiológicos, permitiendo a Farmacias Siman ajustar sus modelos de inventario ante alertas sanitarias o cambios regulatorios.

**2.2.7 CONTEXTO ORGANIZACIONAL: FARMACIAS SIMAN**

**2.2.7.1 PROCESOS OPERATIVOS Y CAPACIDADES ACTUALES**

Los procesos operativos en Farmacias Siman reflejan un modelo de gestión farmacéutica tradicional caracterizado por la combinación de sistemas comerciales básicos con procesos manuales establecidos, configuración que presenta tanto fortalezas operativas como limitaciones informacionales que condicionan las oportunidades de desarrollo de soluciones analíticas avanzadas. El flujo de reabastecimiento opera mediante un sistema mixto donde las decisiones de compra se fundamentan en revisiones periódicas de inventario físico, complementadas con la experiencia acumulada del personal farmacéutico para ajustar cantidades según patrones de demanda observados empíricamente.

Este proceso, aunque funcionalmente efectivo para operaciones rutinarias, presenta limitaciones estructurales para anticipar la demanda futura y optimizar los inventarios de forma sistemática, aspectos que se han identificado como fundamentales para mitigar los quiebres de stock que constituyen el problema central abordado por la propuesta. La gestión de inventarios se ejecuta mediante sistemas de punto de venta que registran transacciones individuales y actualizan automáticamente el stock disponible, generando bases de datos transaccionales que actualmente se utilizan principalmente para control administrativo y contable.

Los procesos de dispensación farmacéutica, por su parte, generan información valiosa sobre patrones de consumo, preferencias de productos, estacionalidad de la demanda, y correlaciones entre diferentes categorías terapéuticas que actualmente no se explotan analíticamente para generar insights predictivos. La coordinación con proveedores se gestiona mediante interacciones comerciales directas y sistemas tradicionales de órdenes de compra que, aunque valiosos para mantener relaciones comerciales sólidas, carecen de capacidades predictivas que optimicen las frecuencias de pedido basándose en análisis sistemático de la demanda futura proyectada.

#### 2.2.7.2 INFRAESTRUCTURA Y CAPACIDADES TECNOLÓGICAS DE INFORMACIÓN DISPONIBLES

La infraestructura tecnológica de Farmacias Siman combina sistemas comerciales estándar con soluciones adaptadas localmente, creando un ecosistema funcional que presenta oportunidades significativas de modernización mediante la incorporación de capacidades analíticas avanzadas. Los sistemas de punto de venta proporcionan funcionalidades esenciales de registro transaccional detallado y control de inventario en tiempo real, capturando información granular de ventas que constituye la base de datos primaria para el desarrollo de modelos predictivos especializados.

La conectividad de red en la sucursal de San Pedro Sula permite el intercambio fluido de información y la sincronización con bases de datos centralizadas, constituyendo un habilitador tecnológico clave para arquitecturas híbridas que combinen procesamiento local con capacidades analíticas avanzadas ejecutadas en la nube. Las capacidades de almacenamiento local son adecuadas para datos operativos cotidianos, pero requieren complemento con soluciones de almacenamiento escalable para los volúmenes de datos históricos necesarios para entrenar y validar modelos predictivos robustos.

Los sistemas de respaldo actuales garantizan la continuidad operativa básica mediante procedimientos manuales y automáticos, aunque carecen de mecanismos automatizados de recuperación que aseguren la disponibilidad continua de servicios analíticos críticos en caso de fallas de infraestructura. La arquitectura de red actual soporta conectividad estable con proveedores de servicios en la nube, facilitando la implementación de soluciones híbridas que aprovechen tanto las capacidades locales como los servicios especializados disponibles

externamente.

### 2.2.7.3 DATOS DISPONIBLES, CALIDAD Y RESTRICCIONES DE USO

La caracterización detallada de los datos disponibles y sus restricciones específicas de uso constituye un elemento fundamental para evaluar la viabilidad técnica del modelo de información con capacidades predictivas propuesto. Los datos organizacionales de Farmacias Siman representan activos estratégicos que, gestionados apropiadamente, pueden generar inteligencia accionable para mejorar significativamente la toma de decisiones operativas relacionadas con la gestión de inventarios y el servicio al cliente.

En el diseño del modelo, se priorizan los conjuntos de datos efectivamente accesibles (ventas e inventarios). La información complementaria, como datos de proveedores, registros de promociones, tendencias epidemiológicas e información meteorológica, se identifica como insumo potencial para fases posteriores de enriquecimiento del modelo. Los datos transaccionales primarios incluyen registros detallados de ventas por producto individual, “inventarios con información de lotes y fechas de vencimiento cuando está disponible, reconociendo posibles brechas de completitud que deben gestionarse en la curaduría de datos. Esta información constituye la base fundamental para desarrollar modelos predictivos especializados que aborden las necesidades específicas identificadas en los objetivos del proyecto.

La información complementaria abarca datos de proveedores con evaluaciones de desempeño histórico, registros detallados de promociones y campañas con métricas de efectividad, tendencias epidemiológicas locales obtenidas de fuentes públicas, información meteorológica que puede correlacionarse con patrones estacionales de demanda, y registros apropiadamente anonimizados de interacciones con clientes que enriquecen el contexto analítico sin comprometer la privacidad individual.

Las restricciones de privacidad y confidencialidad se derivan principalmente de la normativa sectorial aplicable (sanitaria y comercial) y de compromisos internos; ante la ausencia de un marco transversal específico de datos/IA plenamente operacional, se plantea la adopción voluntaria de buenas prácticas internacionales como referencia de control. Los procedimientos de gestión de la información deben equilibrar cuidadosamente el valor analítico potencial con el

cumplimiento estricto de normativas de privacidad y la protección de información comercial sensible que podría comprometer ventajas competitivas si se divulga inadecuadamente.

La implementación de controles de acceso basados en roles y responsabilidades permite una segregación efectiva de funciones, donde el personal analítico accede únicamente a información agregada y anonimizada necesaria para desarrollar modelos, mientras que el personal operativo mantiene acceso completo a los datos específicos requeridos para sus funciones diarias de dispensación y atención al cliente. La segregación de funciones entre perfiles analíticos y operativos puede alinearse con los principios de gestión de identidades y accesos descritos en marcos como el NIST CSF 2.0.

### **2.3 TEORÍAS DE SUSTENTO**

La construcción del modelo de información propuesto no se fundamenta en la adopción instrumental de herramientas tecnológicas aisladas, sino en una arquitectura teórica integrada que busca resolver la tensión estructural identificada en el planteamiento del problema: la necesidad crítica de alta disponibilidad operativa frente a las severas restricciones de recursos y capacidades de un entorno farmacéutico en vías de desarrollo. Este marco conceptual fusiona la rigurosidad normativa de los principios de gestión de calidad farmacéutica (ICH) con el dinamismo evolutivo de los paradigmas de transformación digital (Pharma 4.0) y la solidez estructural de los estándares de arquitectura empresarial y confiabilidad en la nube (TOGAF, NIST, SRE).

Esta selección teórica no es arbitraria ni accesorio; responde a una lógica deductiva derivada estrictamente de los hallazgos del entorno analizados en las secciones previas. Del análisis del macroentorno (PESTEL), que evidenció una profunda asimetría regulatoria y brechas en los marcos de estandarización en Honduras, surge la necesidad imperativa de adoptar controles técnicos y prácticas internacionales de seguridad y confiabilidad para mitigar el riesgo institucional *ab initio*. Simultáneamente, del análisis del microentorno (Porter), donde la disponibilidad se perfila como el único diferenciador competitivo sostenible frente a la agresiva guerra de precios regional, se desprende la urgencia de instrumentar fundamentos de analítica predictiva robusta y arquitecturas en la nube gestionadas bajo principios de resiliencia mensurable (SRE), capaces de transformar datos dispersos en ventajas competitivas tangibles.

Estos referentes teóricos se han seleccionado por su correspondencia biunívoca con las variables operacionalizadas en los objetivos específicos de la investigación. En el contexto de la modernización tecnológica en mercados emergentes, la literatura reciente enfatiza que la tecnología por sí sola es insuficiente si no se gestiona mediante modelos adaptativos que consideren la madurez organizacional:

La integración exitosa de tecnologías de la Industria 4.0 en cadenas de suministro farmacéuticas requiere no solo infraestructura tecnológica avanzada, sino también modelos organizacionales adaptativos que faciliten la transición desde procesos tradicionales hacia ecosistemas digitales integrados. (Al-Hourani & Weraikat, 2025, p. 16).

Esta perspectiva teórica justifica por qué el presente estudio trasciende la mera implementación de código para abordar la estructura de soporte y los procesos de gestión, alineándose con la visión de que la transformación digital es, ante todo, un cambio en la cultura de gestión del riesgo y la toma de decisiones basada en evidencia.

**Tabla 11.** *Alineación de Teorías de Sustento con Objetivos Específicos*

<b>Teoría/Marco Conceptual</b>	<b>Objetivos que Fundamenta</b>	<b>Aplicación Específica y Justificación Teórica</b>
<b>ICH Q10 + ICH Q9(R1)</b>	OE1, OE4	<b>Gestión de Calidad:</b> Proporciona el enfoque de riesgo sanitario que complementa los atributos técnicos de calidad de software (ISO/IEC 25010), redefiniendo conceptualmente el 'quiebre de stock' como un riesgo crítico para la continuidad del tratamiento del paciente.
<b>ISPE Pharma 4.0</b>	OE1, OE4	<b>Madurez Digital:</b> Proporciona el marco evolutivo para demostrar valor operativo incremental, evitando inversiones prematuras ("tecnología por tecnología") sin retorno medible.
<b>Fundamentos de Analítica Predictiva</b>	OE2, OE4	<b>Modelado Matemático:</b> Justifica epistemológicamente la selección de técnicas de aprendizaje automático ( <i>Gradient Boosting</i> ) para datos de alta volatilidad y ruido.

<b>Validación Temporal (Backtesting)</b>	OE2, OE4	<b>Robustez Predictiva:</b> Base teórica para la selección de modelos y la evaluación del desempeño mediante protocolos <i>walk-forward</i> , simulando condiciones operativas reales y evitando sesgos de datos futuros.
<b>TOGAF ADM</b>	OE3	<b>Alineación Estratégica:</b> Metodología iterativa que asegura la trazabilidad entre los requisitos del negocio (disponibilidad) y los componentes tecnológicos desplegados, rompiendo los silos de información.
<b>NIST SP 800-145 (Cloud)</b>	OE3	<b>Eficiencia Operativa:</b> Define teóricamente las características esenciales de la nube (elasticidad, servicio medido) necesarias para viabilizar financieramente el proyecto (OPEX).
<b>Site Reliability Engineering (SRE)</b>	OE3	<b>Confiabilidad Mensurable:</b> Marco teórico para operacionalizar la disponibilidad mediante indicadores matemáticos precisos (SLO, SLI, Error Budget), eliminando la subjetividad en la operación.
<b>Google Cloud Architecture Framework</b>	OE3	<b>Excelencia Técnica:</b> Principios de diseño para garantizar seguridad y eficiencia en la nube, operacionalizados mediante listas de verificación ( <i>checklists well-architected</i> ) validadas.

*Nota.* Elaboración propia. La tabla resume la relación conceptual entre los marcos teóricos y los objetivos específicos; la selección y aplicación concreta de estos referentes se detalla en el capítulo de metodología.

### 2.3.1 CUARTA REVOLUCIÓN INDUSTRIAL APLICADA A SALUD

La Cuarta Revolución Industrial (4RI) representa un cambio de paradigma que trasciende la automatización industrial para centrarse en la inteligencia de datos y la interconectividad. En el sector salud, y específicamente en la gestión farmacéutica de países en desarrollo, esta teoría proporciona el marco conceptual fundamental para comprender cómo transformar procesos que son tradicionalmente manuales, reactivos y fragmentados ("silos de datos") en sistemas proactivos, integrados y fundamentados en evidencia analítica.

Para operacionalizar este concepto en un entorno regulado, se recurre a los marcos del Consejo Internacional de Armonización (ICH). El sistema de calidad farmacéutica ICH Q10 aporta

una visión integral del ciclo de vida, mientras que la revisión ICH Q9(R1) actualiza la gestión de riesgos de calidad (International Council for Harmonisation, 2023). Este enfoque permite interpretar el "quiebre de stock" no solo como un problema logístico, sino como un riesgo de calidad que impacta la seguridad del paciente. Estos principios de alto nivel se traducen operativamente en requisitos funcionales y no funcionales, cuya medición técnica se realiza bajo el estándar de ingeniería de software ISO/IEC 25010, asegurando así un puente sólido entre la teoría de calidad farmacéutica y la ingeniería de sistemas.

Complementariamente, el modelo ISPE Pharma 4.0 articula un camino de madurez digital que recomienda avanzar desde la digitalización básica hacia la predictibilidad. Este enfoque valida teóricamente la estrategia del proyecto de demostrar valor en pequeñas escalas mediante pilotos y métricas claras antes de realizar grandes inversiones de capital (International Society for Pharmaceutical Engineering, 2023). Estos principios fundamentan los indicadores de evaluación del Objetivo Específico 4, estableciendo que el éxito del modelo no es solo técnico (precisión del algoritmo), sino operativo (utilidad percibida).

### 2.3.2 ANALÍTICA PREDICTIVA Y APRENDIZAJE AUTOMÁTICO EN CADENAS DE SUMINISTROS

La analítica predictiva aplicada a cadenas de suministro busca anticipar sistemáticamente la demanda futura mediante modelos matemáticos que aprenden de patrones históricos y variables exógenas. Esta perspectiva teórica constituye el pilar del Segundo Objetivo Específico (OE2), proporcionando los criterios científicos para seleccionar técnicas capaces de manejar la complejidad, la no linealidad y el ruido inherente al mercado hondureño.

Los modelos de aprendizaje automático supervisado, y específicamente las técnicas de ensamblaje como Gradient Boosting, son frecuentemente reportados en la literatura científica como enfoques robustos y competitivos frente a métodos estadísticos tradicionales (como ARIMA) en contextos de alta volatilidad. La teoría sugiere que, en escenarios donde los datos históricos son limitados o presentan estacionalidad compleja (una característica consistente con el contexto del caso y con las limitaciones del histórico disponible), los algoritmos basados en árboles de decisión con técnicas de regularización ofrecen un equilibrio óptimo entre sesgo y varianza (bias-variance tradeoff), evitando el sobreajuste y mejorando la capacidad de generalización.

Para validar esta capacidad predictiva, se adopta teóricamente el enfoque de Validación Temporal (Walk-Forward Validation). A diferencia de la validación cruzada tradicional, este método respeta la estructura temporal de los datos, simulando el flujo real de información que enfrentaría un gerente de farmacia al tomar decisiones. Esto asegura que las métricas de error (MAE, MAPE) reflejen con fidelidad la robustez del modelo en un entorno productivo, dando soporte tanto a la selección técnica (OE2) como a la evaluación de viabilidad (OE4).

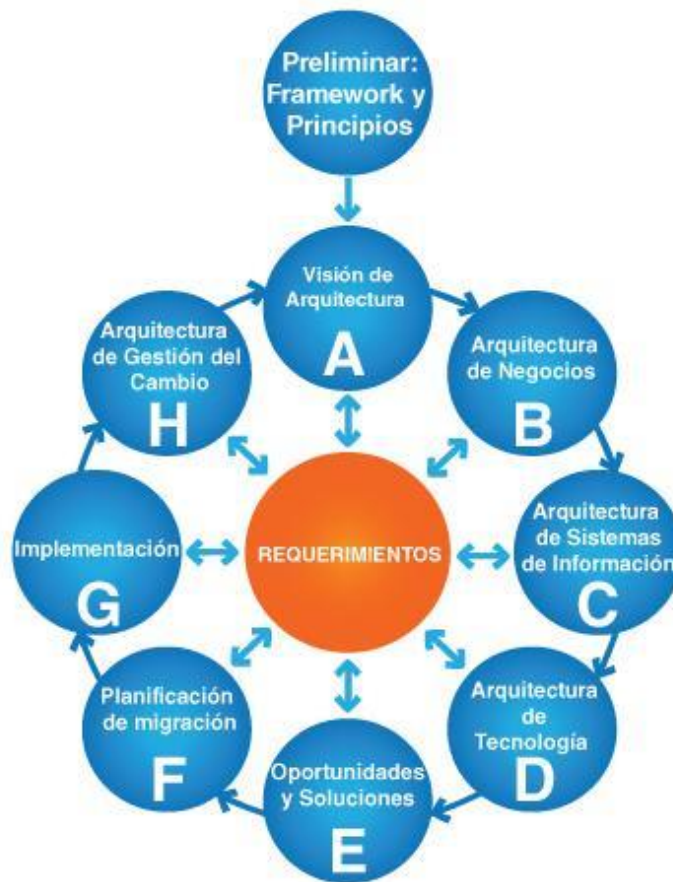
### 2.3.3 COMPUTACIÓN EN LA NUBE Y ARQUITECTURA EMPRESARIAL PARA SISTEMAS FARMACÉUTICOS

El diseño de la solución tecnológica (OE3) no puede limitarse a la funcionalidad del software; debe garantizar la operabilidad, la seguridad y la resiliencia en un entorno productivo real. Para ello, la investigación integra tres pilares conceptuales que sustentan directamente las dimensiones medidas en los instrumentos metodológicos:

1. **Arquitectura Empresarial (TOGAF):** El estándar **TOGAF** proporciona el método estructurado (ADM) para alinear la tecnología con los objetivos de negocio. Su enfoque iterativo fundamenta la definición de los componentes técnicos y flujos de datos documentados en la investigación, asegurando que cada elemento de la arquitectura responda a un requerimiento funcional identificado y validado (The Open Group, 2022).
2. **Computación en la Nube (NIST):** La definición del **NIST SP 800-145** establece las características esenciales de la nube, tales como la *elasticidad rápida* y el *servicio medido* (Mell & Grance, 2011). La elasticidad justifica teóricamente cómo Farmacias Siman puede acceder a computación de alto rendimiento para entrenar modelos complejos de IA sin incurrir en costos fijos prohibitivos (*CAPEX*), transformando el gasto en operativo variable (*OPEX*).
3. **Ingeniería de Confiabilidad (SRE):** Para operacionalizar la dimensión de disponibilidad y gestión de fallos, se adoptan los principios de *Site Reliability Engineering* (SRE). SRE proporciona el marco teórico para dejar de tratar la confiabilidad como un concepto abstracto y medirla mediante Objetivos de Nivel de Servicio (**SLO**), Indicadores de Nivel de Servicio (**SLI**) y Presupuestos de Error (*Error Budgets*). Beyer et al. (2016) establecen

que la confiabilidad es la característica más crítica de cualquier sistema productivo; este enfoque justifica teóricamente por qué los instrumentos de la tesis miden la disponibilidad en porcentajes exactos y definen tiempos de recuperación.

Asimismo, la seguridad y la excelencia operativa se sustentan en los principios del Google Cloud Architecture Framework, que traducen las mejores prácticas de la industria (seguridad, confiabilidad, rendimiento, optimización de costos) en listas de verificación técnicas (*checklists well-architected*) aplicables específicamente a la infraestructura seleccionada, proporcionando una capa de aseguramiento técnico validable.



**Ilustración 4.** El Ciclo del Método de Desarrollo de Arquitectura (ADM) de TOGAF.

*Nota.* Adaptado de *The TOGAF® Standard, 10th Edition*, por The Open Group (2022). El ciclo sustenta la estructuración iterativa de los componentes del modelo y la mejora continua de la arquitectura.

En conclusión, la integración sinérgica de estos marcos proporciona la base científica necesaria para diseñar una solución tecnológica que no solo sea capaz de predecir la demanda con precisión matemática, sino que sea lo suficientemente robusta, segura y financieramente viable para operar de manera sostenible en el contexto real y desafiante de Farmacias Siman.

## 2.4 ANÁLISIS DE LAS METODOLOGÍAS

Esta sección presenta un análisis comparativo de metodologías y marcos reportados en la literatura para fundamentar la elección conceptual de los enfoques técnicos. Con base en la arquitectura teórica establecida en la sección anterior, la estrategia metodológica se operacionaliza para transitar desde la gestión tradicional hacia la madurez digital (Pharma 4.0). Esta transición no se logra únicamente con la adopción tecnológica descrita en las teorías de sustento, sino mediante un mecanismo de transformación del conocimiento organizacional.

Para vincular la teoría con la práctica operativa, se articula el modelo **SECI** (Socialización, Externalización, Combinación, Internalización) de Nonaka y Takeuchi (1995). Este marco metodológico actúa como el vehículo que permite materializar los principios de la Industria 4.0: transforma el conocimiento tácito y disperso de la farmacia en inteligencia explícita y accionable.

La metodología integra dos enfoques complementarios validados en la literatura para resolver la fragmentación operativa:

1. **Análítica Predictiva (Gradient Boosting):** Operacionaliza la fase de *Externalización* del modelo SECI, codificando la intuición humana en algoritmos matemáticos auditables.
2. **Arquitectura Empresarial (TOGAF ADM):** Operacionaliza la fase de *Combinación*, estructurando los dominios de negocio, datos y tecnología para asegurar la gobernanza y escalabilidad de la solución.

Esta convergencia metodológica responde directamente a la necesidad de resiliencia identificada por Al-Hourani y Weraikat (2025), quienes advierten que la efectividad de la inteligencia artificial en cadenas de suministro depende de su integración con estructuras organizacionales adaptativas.

## 2.4.1 MACHINE LEARNING PARA DESARROLLO DE MODELO PREDICTIVO

### 2.4.1.1 EVOLUCIÓN Y SELECCIÓN DE ENFOQUES EN LA LITERATURA ESPECIALIZADA

La gestión de la cadena de suministro farmacéutica ha experimentado un cambio de paradigma, evolucionando desde métodos estocásticos tradicionales hacia la inteligencia artificial. Nguyen et al. (2022) establecen en su revisión sistemática que, si bien los métodos estadísticos clásicos (como ARIMA) ofrecen interpretabilidad, carecen de la flexibilidad necesaria para capturar la volatilidad exógena y la no linealidad de los mercados modernos.

Por otro lado, aunque las redes neuronales profundas (Deep Learning, LSTM) han demostrado superioridad en contextos de Big Data, presentan limitaciones severas en entornos con historias transaccionales cortas. Rathipriya et al. (2023) advierten sobre el riesgo de sobreajuste (overfitting) cuando se aplican arquitecturas profundas a conjuntos de datos pequeños (~90 días), lo que resulta en modelos inestables.

En este contexto, la familia de algoritmos de Gradient Boosting emerge como la solución óptima. Fourkiotis y Tsadiras (2024) demuestran empíricamente que los ensambles de árboles de decisión (como XGBoost) superan consistentemente a los modelos estadísticos y a las redes neuronales en tareas de pronóstico de demanda farmacéutica, ofreciendo el equilibrio ideal entre precisión y eficiencia computacional.

**Tabla 12.** *Análisis Comparativo de Enfoques Algorítmicos en Contextos de Datos Limitados*

<b>Enfoque Metodológico</b>	<b>Fundamento Matemático</b>	<b>Limitaciones Estructurales (Contexto Siman)</b>	<b>Justificación de Selección</b>
<b>Estadístico Clásico (ARIMA)</b>	Autoregresión lineal y medias móviles.	<b>Rigidez:</b> Incapaz de modelar interacciones complejas no lineales o cambios abruptos sin re-parametrización.	<b>Descartado</b> como motor principal; se mantiene como línea base (Benchmark).

<b>Deep Learning (RNN/LSTM)</b>	Redes neuronales recurrentes.	<b>Opacidad y Costo:</b> Naturaleza de "Caja Negra" y alta demanda de datos históricos para converger.	<b>Descartado</b> por riesgo de sobreajuste en ventanas cortas de tiempo.
<b>Gradient Boosting (XGBoost)</b>	Aprendizaje por ensamblaje secuencial minimizando pérdida diferenciable.	<b>Sensibilidad a Hiperparámetros:</b> Requiere validación cruzada robusta.	<b>Seleccionado.</b> Mejor equilibrio sesgo-varianza y permite interpretabilidad.

*Nota.* Elaboración propia basada en la revisión crítica de Fourkiotis y Tsadiras (2024), Nguyen et al. (2022) y Rathipriya et al. (2023).

### 2.4.1.2 JUSTIFICACIÓN TEÓRICA: EXPLICABILIDAD Y GOBERNANZA DEL ALGORITMO

La elección de Gradient Boosting no responde únicamente a métricas de precisión, sino a la necesidad de gobernanza algorítmica alineada con Pharma 4.0. A diferencia de las redes neuronales, las implementaciones modernas de Boosting permiten descomponer la predicción mediante valores SHAP (Shapley Additive Explanations). Esta característica es fundamental para la fase de Internalización del modelo SECI, ya que genera confianza en el usuario experto y facilita la adopción tecnológica al explicar por qué se sugiere una reposición.

### 2.4.2 TOGAF ADM PARA ESPECIFICACIÓN ARQUITECTÓNICA

La implementación de modelos predictivos sin una estructura de gobierno adecuada conduce a la creación de silos de información. Para mitigar este riesgo, la investigación adopta el **Architecture Development Method (ADM)** de TOGAF como marco metodológico para garantizar la alineación estratégica entre la tecnología y el negocio.

La aplicación de TOGAF se realiza mediante una adaptación (*tailoring*) de sus fases centrales:

- **Fase B (Arquitectura de Negocio):** Modela los procesos de reposición "To-Be" (OE1).
- **Fase C (Arquitectura de Sistemas de Información):** Define la calidad de datos y las

APIs de ingestión necesarias para alimentar el algoritmo.

- **Fase D (Arquitectura Tecnológica):** Diseña la infraestructura en Google Cloud Platform (GCP), priorizando servicios *serverless* para maximizar la viabilidad financiera (OE3).

**Tabla 13.** *Evaluación de Marcos de Arquitectura Empresarial para Salud Digital*

Marco Arquitectónico	Enfoque Ontológico	Idoneidad para el Proyecto	Argumento de Selección
<b>Zachman Framework</b>	Taxonomía descriptiva.	<b>Baja.</b> Cadece de metodología de implementación paso a paso.	Descartado por ser estático.
<b>TOGAF ADM</b>	Proceso iterativo de ciclo de vida.	<b>Alta.</b> Método probado para traducir requisitos de negocio en especificaciones técnicas.	<b>Seleccionado.</b> Gestiona la integración nube-analítica estructuradamente.

*Nota.* Elaboración propia basada en The Open Group (2022).

### 2.4.3 ANÁLISIS COMPARATIVO INTEGRAL Y APOORTE METODOLÓGICO

Para evidenciar la contribución científica y responder a la necesidad de diferenciar la propuesta frente a métodos previos, se contrastan las dimensiones metodológicas en dos niveles: frente a la operación actual (Tabla 14) y frente al estado del arte en la literatura (Tabla 15).

**Tabla 14.** *Transformación del Modelo Operativo: Línea Base vs. Propuesta*

Dimensión (SECI / Pharma 4.0)	Metodología Actual (Gestión Tácita)	Metodología Propuesta (Gestión Explícita)
<b>Gestión del Conocimiento</b>	<b>Fragmentada.</b> Dependiente de la memoria individual.	<b>Sistematizada.</b> Conocimiento codificado en algoritmos auditables.
<b>Enfoque Temporal</b>	<b>Reactivo.</b> Análisis de quiebres ya materializados.	<b>Proactivo.</b> Anticipación probabilística de la demanda futura.

<b>Toma de Decisiones</b>	<b>Subjetiva.</b> Basada en intuición o promedios simples.	<b>Basada en Evidencia.</b> Soporte mediante alertas priorizadas.
---------------------------	--	---

Nota. Elaboración propia.

**Tabla 15.** Matriz de Convergencia: Metodologías Previas en Literatura vs. Integración Propuesta

<b>Enfoque Metodológico Previo (Literatura)</b>	<b>Brecha Detectada (Gap Metodológico)</b>	<b>Solución Integradora de la Propuesta</b>
<b>Analítica Aislada (Nguyen et al., 2022)</b>	Estudios centrados en la precisión técnica desconectados de la gobernanza.	<b>Integración TOGAF + ML.</b> Envuelve el algoritmo (OE2) en una arquitectura empresarial (OE3) sostenible.
<b>Gemelos Digitales Complejos (Badakhshan et al., 2022)</b>	Requieren simulación compleja y datos masivos costosos.	<b>Enfoque "Lean".</b> Adopta la lógica predictiva sobre arquitectura <i>serverless</i> costo-eficiente.
<b>Predicción Matemática Pura (Fourkiotis &amp; Tsadiras, 2024)</b>	Maximizan métricas técnicas ignorando la utilidad práctica.	<b>Enfoque Sociotécnico (OE4).</b> Evalúa la utilidad operativa, cerrando el ciclo de <b>Internalización SECI.</b>

Nota. Elaboración propia. Esta matriz demuestra cómo la propuesta llena el vacío entre la investigación teórica avanzada y la aplicabilidad práctica.

**Convergencia Metodológica: SECI y Pharma 4.0**

La propuesta no solo integra herramientas técnicas, sino que operacionaliza marcos de gestión del conocimiento previos. El modelo SECI (Socialización, Externalización, Combinación, Internalización) se aplica para transformar el conocimiento tácito del farmacéutico (reglas empíricas) en algoritmos explícitos (Gradient Boosting), cerrando el ciclo con la internalización mediante el uso de alertas en la toma de decisiones. Esta integración alinea la propuesta con los principios de Pharma 4.0, transitando de la digitalización pasiva a la inteligencia accionable.

## 2.5 ANTECEDENTES DE LAS METODOLOGÍAS

El desarrollo metodológico de este estudio se fundamenta en la convergencia documentada de dos disciplinas: la aplicación de aprendizaje automático en gestión farmacéutica y el desarrollo de arquitecturas empresariales especializadas para el sector salud. La comprensión de esta convergencia proporciona contexto esencial para las decisiones metodológicas adoptadas y establece la base conceptual que justifica los enfoques seleccionados.

### 2.5.1 EVOLUCIÓN DEL MACHINE LEARNING FARMACÉUTICO

La aplicación de técnicas de aprendizaje automático en gestión farmacéutica ha experimentado una transformación significativa hacia sistemas analíticos especializados capaces de procesar relaciones multidimensionales complejas en datos operativos farmacéuticos. Esta evolución se caracteriza por la transición desde enfoques estadísticos tradicionales hacia metodologías adaptativas que aprovechan capacidades computacionales avanzadas.

#### 2.5.1.1 TRANSICIÓN HACIA APRENDIZAJE AUTOMÁTICO ESPECIALIZADO

Nguyen et al. (2022) documentan la transformación de las cadenas farmacéuticas desde enfoques reactivos hacia modelos proactivos mediante analítica avanzada e inteligencia artificial. Esta transformación establece que los enfoques predictivos basados en aprendizaje automático representan una evolución natural desde modelos estadísticos tradicionales hacia sistemas adaptativos capaces de procesar múltiples variables interdependientes simultáneamente.

La transición hacia metodologías de aprendizaje automático fue catalizada por el reconocimiento de limitaciones inherentes en enfoques estadísticos tradicionales para capturar la complejidad real de ecosistemas farmacéuticos modernos, caracterizados por carteras diversificadas de productos, múltiples canales de distribución y variabilidad estocástica en patrones de consumo influenciados por factores socioeconómicos, culturales y epidemiológicos.

#### 2.5.1.2 ERA CONTEMPORÁNEA: ESPECIALIZACIÓN FARMACÉUTICA

La especialización de técnicas para contextos farmacéuticos específicos representa el desarrollo más relevante para organizaciones como Farmacias Siman. Rathipriya et al. (2023)

desarrollaron modelos optimizados para datos farmacéuticos y concluyeron que los modelos menos complejos superaron a las redes profundas debido a su mayor capacidad para tolerar el ruido característico de los conjuntos de datos limitados. La evidencia cuantificable de efectividad ha consolidado la adopción: Fourkiotis y Tsadiras (2024) documentan errores de predicción entre 16.05-17.98% en transacciones farmacéuticas usando gradient boosting, mientras que Badakhshan et al. (2022) reportan mejoras significativas en métricas operacionales mediante enfoques híbridos.

## 2.5.2 DESARROLLO DE ARQUITECTURAS EMPRESARIALES EN SALUD

La aplicación de frameworks de arquitectura empresarial en contextos sanitarios ha evolucionado hacia marcos especializados que abordan las complejidades únicas del sector salud: interoperabilidad crítica, cumplimiento regulatorio estricto y gestión de datos altamente sensibles.

### 2.5.2.1 MARCOS ESPECIALIZADOS REGIONALES

La evolución hacia marcos especializados ha sido impulsada por iniciativas regionales documentadas. El Plan de Acción IS4H 2024–2030 enfatiza el fortalecimiento de la gestión y gobernanza de sistemas de información, la interoperabilidad basada en estándares, y el desarrollo de capacidades para la transformación digital regional (Pan American Health Organization, 2024). La estructura modular de TOGAF versión 10 facilita adopción selectiva de componentes específicos sin imposición de complejidades innecesarias, diferenciando entre Contenido Fundamental que proporciona conceptos universales, y Guías Extendidas que ofrecen orientación especializada para aplicaciones farmacéuticas que requieren consideraciones únicas de cumplimiento regulatorio y trazabilidad operacional.

### 2.5.2.2 ANTECEDENTE NACIONAL: EL SISTEMA SALMI Y LA GESTIÓN LOGÍSTICA

En el contexto nacional hondureño, el antecedente metodológico de referencia es el Sistema de Administración Logística de Medicamentos e Insumos (SALMI), implementado en la red pública con el soporte técnico de la OPS/OMS. Este sistema ha sido fundamental para estandarizar los procesos de requisición y almacenamiento, validando la viabilidad de la gestión digital de inventarios en entornos de recursos limitados (OPS, 2022).

Sin embargo, desde una perspectiva de arquitectura empresarial, SALMI presenta una brecha metodológica significativa frente a las necesidades del sector *retail* privado: su diseño es determinista y administrativo, enfocado en el registro transaccional de movimientos y el control de máximos y mínimos fijos. No incorpora componentes de analítica predictiva ni aprendizaje automático para modelar la incertidumbre de la demanda, una capacidad crítica para el sector privado que opera en un mercado abierto y competitivo. Por consiguiente, aunque SALMI valida la digitalización logística en el país, justifica la necesidad de evolucionar hacia arquitecturas predictivas (como la propuesta en esta tesis) que superen la gestión descriptiva y permitan la anticipación inteligente de quiebres de stock.

### 2.5.3 CONVERGENCIA METODOLÓGICA

La convergencia documentada entre machine learning especializado y arquitecturas empresariales adaptadas proporciona el fundamento metodológico para el modelo propuesto. Esta convergencia se materializa mediante la integración de capacidades predictivas (gradient boosting) con especificaciones arquitectónicas (TOGAF ADM) que respondan específicamente a los desafíos informacionales identificados en el contexto de Farmacias Siman.

#### 2.5.3.1 FUNDAMENTOS EMPÍRICOS DE LA CONVERGENCIA

La selección específica de Gradient Boosting como algoritmo central se fundamenta en evidencia empírica documentada en contextos farmacéuticos similares. Fourkiotis y Tsadiras (2024) demuestran que Gradient Boosting alcanza errores de predicción entre 16.05-17.98% en análisis de transacciones farmacéuticas, proporcionando precisión predictiva superior comparada con métodos estadísticos tradicionales. Aunque su estudio se basa en un horizonte de datos más amplio (>12 meses), la evidencia cuantificada respalda la selección de gradient boosting como algoritmo central. En este trabajo se anticipa conceptualmente que, con solo 90 días de históricos, los errores de pronóstico serán mayores que en estudios con series anuales completas; el desempeño real observado se reporta y analiza en el Capítulo IV.

#### 2.5.3.2 INTEGRACIÓN ARQUITECTÓNICA VALIDADA

La implementación de marcos arquitectónicos en contextos latinoamericanos requiere adaptaciones que reconozcan tanto las capacidades existentes como las aspiraciones de

transformación digital del sector salud. El Plan de Acción IS4H 2024-2030 enfatiza la necesidad de sistemas diseñados con interoperabilidad basada en estándares, seguridad integral, y enfoque en las necesidades de salud de las personas, facilitando el intercambio de información entre proveedores sanitarios diversos (Pan American Health Organization, 2024). En Honduras, la Hoja de Ruta de Transformación Digital en Salud (Fase 1: 2024–2025) establece prioridades en gobernanza, interoperabilidad y Expediente Único Interoperable de Salud (EUIS), proporcionando el marco normativo nacional que facilita la implementación de plataformas farmacéuticas digitales alineadas con objetivos estratégicos de modernización sanitaria (Secretaría de Salud de Honduras, 2024).

La aplicación de TOGAF Architecture Development Method en contextos sanitarios cuenta con validación empírica mediante iniciativas regionales documentadas. La especificación arquitectónica propuesta aprovecha la modularidad inherente de TOGAF versión 10, que facilita adopción selectiva de componentes específicos sin imposición de complejidades innecesarias. Esta característica resulta particularmente relevante para organizaciones de escala media como Farmacias Siman, donde la implementación debe equilibrar capacidades avanzadas con restricciones operativas y presupuestarias.

### 2.5.3.3 VALIDACIÓN MEDIANTE MARCOS DE GESTIÓN DE RIESGOS

La convergencia metodológica incorpora criterios de gestión de riesgos específicos para sistemas de inteligencia artificial establecidos por organismos reconocidos. El NIST AI RMF (2023) incluye la explicabilidad e interpretabilidad como características de IA confiable, requisito que se satisface mediante las capacidades nativas de explicabilidad de gradient boosting y su integración con interfaces de usuario especificadas según principios TOGAF.

Esta alineación con marcos de gestión de riesgos gubernamentales proporciona fundamento conceptual para el diseño de alertas contextualizadas que mantengan transparencia algorítmica mientras generan información accionable para decisiones operativas críticas. La convergencia metodológica asegura que las capacidades predictivas avanzadas operen dentro de parámetros de gobernanza apropiados para contextos farmacéuticos.

### 2.5.3.4 EVIDENCIA DE APLICABILIDAD SECTORIAL

Badakhshan et al. (2022) proporcionan evidencia empírica sobre la efectividad de enfoques híbridos que combinan simulación y aprendizaje automático en gestión de cadenas de suministro farmacéuticas, documentando "mejoras significativas en métricas clave de desempeño operacional" (art. 110649). Esta evidencia valida la viabilidad de convergencias metodológicas similares a la propuesta, donde capacidades analíticas se integran con especificaciones arquitectónicas para generar valor operativo cuantificable.

Al-Hourani y Weraikat (2025) establecen que la integración exitosa de tecnologías de la Industria 4.0 en cadenas de suministro farmacéuticas requiere no solo infraestructura tecnológica avanzada, sino también modelos organizacionales adaptativos que faciliten la transición desde procesos tradicionales hacia ecosistemas digitales integrados.

#### 2.5.3.5 INFRAESTRUCTURA TECNOLÓGICA HABILITADORA

La implementación de la convergencia metodológica se fundamenta en capacidades de computación en la nube que faciliten integración escalable entre componentes predictivos y arquitectónicos. Mell y Grance (2011) establecen que la computación en la nube proporciona "acceso ubicuo y conveniente bajo demanda a recursos computacionales configurables" (p. 2), características esenciales para soportar tanto el entrenamiento de modelos gradient boosting como la operación de servicios arquitectónicos especificados mediante TOGAF ADM.

Esta convergencia infraestructural permite materializar la gestión informacional avanzada sin requerir inversiones prohibitivas en infraestructura propietaria, aspecto particularmente relevante para el contexto de Farmacias Siman donde la viabilidad económica condiciona las opciones tecnológicas disponibles.

#### 2.5.3.6 IMPLICACIONES PARA IMPLEMENTACIÓN

Las implicaciones para este estudio incluyen oportunidades de adopción de algoritmos probados en contextos farmacéuticos similares, la aplicación de principios arquitectónicos validados en ecosistemas sanitarios latinoamericanos, y la alineación con marcos regulatorios nacionales que faciliten implementación futura y sostenibilidad operacional.

La convergencia metodológica documentada proporciona fundamento conceptual sólido

para especificaciones técnicas que equilibren innovación tecnológica con aplicabilidad práctica, asegurando que la gestión informacional desarrollada genere valor operativo cuantificable dentro de las limitaciones reconocidas del contexto académico y las restricciones específicas del entorno organizacional de Farmacias Siman.

**Tabla 16.** *Convergencia Metodológica: Evidencia Empírica y Aplicaciones*

<b>Componente Metodológico</b>	<b>Evidencia Empírica</b>	<b>Precisión/Mejora Documentada</b>	<b>Aplicabilidad Contextual</b>	<b>Limitaciones Reconocidas</b>
<b>Gradient boosting</b>	Farmacéutico Internacional	Transacciones farmacéuticas reales	MAPE 16.05-17.98%	Datos limitados (90 días); ajuste esperado por backtesting
<b>Modelos Menos Complejos</b>	Investigación Académica	Superior a redes profundas	Tolerancia ruido datos	No especifica volumen mínimo de datos
<b>Enfoques Híbridos ML</b>	Cadenas suministro farmacéuticas	Mejoras significativas métricas operacionales	Convergencia metodológica validada	Contexto industrial (mayor escala que retail)
<b>SALMI (Honduras)</b>	<b>Red Pública Nacional (OPS)</b>	<b>Estandarización y trazabilidad logística</b>	<b>Gestión administrativa determinista</b>	<b>Carece de capacidades predictivas (No IA)</b>
<b>TOGAF + IS4H</b>	Ecosistemas sanitarios regionales	Interoperabilidad y seguridad por diseño	Contextos latinoamericanos	Implementaciones hospital-céntricas, no retail
<b>Frameworks IA Gubernamentales</b>	Sistemas IA explicables	Interpretabilidad y transparencia algorítmica	Gestión riesgos farmacéuticos	Orientación general, no farmacéutica específica
<b>Cloud Computing</b>	Recursos configurables bajo demanda	Acceso ubicuo y escalabilidad	Organizaciones escala media	Costos operativos recurrentes no evaluados

*Nota.* Elaboración propia basada en evidencia empírica documentada de convergencias metodológicas exitosas en contextos farmacéuticos y sanitarios, integrando el debate nacional (Al-Hourani & Weraikat, 2025; Badakhshan et al., 2022; Fourkiotis & Tsadiras, 2024; National Institute of Standards and Technology, 2023; OPS, 2022; Pan American Health Organization, 2024; Rathipriya et al., 2023).

## 2.6 ANÁLISIS CRÍTICO DE LAS METODOLOGÍAS

El análisis crítico de la convergencia metodológica entre el aprendizaje automático (Gradient Boosting) y la arquitectura empresarial (TOGAF) revela tanto oportunidades de innovación como limitaciones estructurales que deben gestionarse para asegurar la viabilidad del modelo. Este ejercicio de reflexividad académica es indispensable para dimensionar el alcance real de los resultados y establecer las fronteras de validez de la propuesta.

La segmentación del análisis aborda las dos dimensiones centrales del diseño: la vulnerabilidad inherente al modelado con datos limitados y la decisión estratégica de adoptar un paradigma de arquitectura sin servidor (Serverless).

### 2.6.1 EVALUACIÓN CRÍTICA DE MACHINE LEARNING CON DATOS LIMITADOS

La aplicación de gradient boosting en el contexto específico de Farmacias Siman presenta un balance complejo entre potencial técnico y restricciones prácticas que requiere análisis cuidadoso para establecer expectativas realistas.

**Fortalezas identificadas:** La robustez documentada de gradient boosting con conjuntos de datos limitados, respaldada por evidencia empírica de Rathipriya et al. (2023), proporciona fundamento técnico sólido para el desarrollo conceptual. La interpretabilidad inherente del algoritmo facilita la generación de explicaciones contextualizadas, mientras que la eficiencia computacional permite desarrollo de prototipos dentro de restricciones académicas típicas.

**Limitaciones críticas:** La restricción de 90 días de datos históricos (aproximadamente un cuarto de año) impide la captura completa de patrones estacionales anuales, limitación particularmente problemática para medicamentos con variación anual pronunciada como antihistamínicos estacionales, antigripales, o tratamientos vinculados a condiciones climáticas específicas. La literatura especializada en pronóstico de series temporales recomienda disponer de al menos dos ciclos completos del patrón estacional para modelarlo de forma confiable (Hyndman

& Athanasopoulos, 2021). La ausencia de variables exógenas (datos epidemiológicos locales, indicadores meteorológicos, ciclos económicos) limita adicionalmente la capacidad de contextualización predictiva y la detección de patrones de demanda inducidos por factores externos observables. La validación restringida a datos históricos disponibles impide evaluación operativa real del impacto en decisiones de reabastecimiento bajo condiciones operacionales auténticas.

**Estrategias de mitigación conceptual:** Agrupación inteligente por categorías ATC/DDD OMS para maximizar aprovechamiento de patrones compartidos, documentación explícita y transparente de limitaciones para orientar interpretación apropiada de resultados, especificación detallada de marcos de mejora continua para implementaciones futuras con mayores volúmenes de datos.

## 2.6.2 EVALUACIÓN CRÍTICA DE LA ARQUITECTURA SERVERLESS

La decisión de implementar la solución sobre una arquitectura *Serverless* (Google Cloud Functions, BigQuery) en lugar de una infraestructura tradicional basada en servidores (IaaS o On-Premise), constituye una postura arquitectónica que prioriza la eficiencia operativa (OPEX) sobre el control de infraestructura.

### 2.6.2.1 JUSTIFICACIÓN FINANCIERA Y OPERATIVA

En el contexto de una farmacia *retail* con márgenes ajustados, la arquitectura tradicional presenta una ineficiencia estructural: mantener un servidor encendido 24/7 para ejecutar un modelo que solo requiere 30 minutos de procesamiento diario implica una subutilización significativa de recursos. El enfoque *Serverless* adoptado alinea el costo tecnológico con el valor del negocio mediante una elasticidad económica pura: se paga únicamente por los milisegundos de cómputo utilizados durante la inferencia. Esto transforma una inversión de capital (CAPEX) rígida en un costo operativo (OPEX) marginal y optimizado.

### 2.6.2.2 RIESGOS DE DEPENDENCIA Y LATENCIA

A pesar de sus ventajas, este enfoque introduce riesgos que deben gestionarse:

- **Vendor Lock-in (Dependencia del Proveedor):** El uso de servicios propietarios como BigQuery genera una alta dependencia de Google Cloud Platform (GCP). Migrar a otro proveedor requeriría una reingeniería del código, riesgo que se acepta a cambio de la velocidad de despliegue.
- **Latencia de Arranque (Cold Start):** Las funciones *serverless* pueden presentar latencia al activarse tras inactividad. Dado que el caso de uso es un proceso por lotes (*batch*) nocturno y no una transacción de tiempo real crítica, esta latencia (segundos) resulta despreciable para la operación de Farmacias Siman.

### 2.6.3 SÍNTESIS DE VIABILIDAD TÉCNICA

La Tabla 17 resume el análisis crítico, contrastando las limitaciones detectadas con las estrategias de arquitectura y modelado diseñadas para mitigarlas.

**Tabla 17.** *Análisis de Viabilidad Técnica y Estrategias de Mitigación ante Limitaciones*

<b>Dominio Crítico</b>	<b>Limitación Identificada</b>	<b>Riesgo Asociado</b>	<b>Estrategia de Mitigación (Diseño)</b>	<b>Expectativa Realista</b>
<b>Datos (ML)</b>	Histórico limitado a 90 días (insuficiente para estacionalidad anual).	Incapacidad de predecir picos estacionales anuales.	Uso de <i>Gradient Boosting</i> (robusto en <i>small data</i> ) y agrupación por familias ATC.	<b>MAPE <math>\leq</math> 25-30%</b> (superior a la intuición humana, pero perfectible con más historia).
<b>Arquitectura</b>	Dependencia de GCP ( <i>Vendor Lock-in</i> ) y abstracción de hardware.	Dificultad de migración futura y pérdida de control granular.	Adopción de estándares de código (Python) y contenedores lógicos.	<b>Reducción de TCO</b> (Costo Total de Propiedad) superior al riesgo de dependencia.
<b>Infraestructura</b>	Ejecución episódica (Batch) en lugar de	Latencia de arranque ( <i>Cold</i>	Arquitectura orientada a eventos (Event-Driven)	Reducción significativa de costos operativos (OPEX) frente a

	continua.	<i>Start</i> ).	asíncrona.	infraestructura dedicada (IaaS).
--	-----------	-----------------	------------	----------------------------------

*Nota.* Elaboración propia. El análisis confirma que, aunque existen limitaciones estructurales (datos) y riesgos estratégicos (dependencia de nube), la arquitectura propuesta es especialmente adecuada para garantizar la viabilidad financiera en el contexto organizacional.

## 2.7 HERRAMIENTAS

La selección del ecosistema tecnológico para esta investigación no constituye una decisión meramente instrumental, sino una definición estratégica que condiciona la viabilidad operativa y financiera del modelo propuesto. Se adopta un enfoque metodológico mixto que requiere herramientas capaces de procesar datos cuantitativos (series temporales transaccionales) y cualitativos (criterios de negocio), integrados bajo una arquitectura de Computación en la Nube.

Siguiendo la definición canónica del NIST (Mell & Grance, 2011), se prioriza el modelo de servicio PaaS (Platform as a Service) y la ejecución Serverless. Esta elección se fundamenta en la necesidad de maximizar la elasticidad de los recursos —accediendo a potentes capacidades de cómputo para el entrenamiento de algoritmos de *Gradient Boosting* solo cuando es necesario— y minimizar la carga administrativa de mantenimiento de infraestructura (*Reducción de carga operativa*), alineándose con las restricciones presupuestarias y de tiempo inherentes a un proyecto académico.

La arquitectura tecnológica se ha diseñado para responder trazablemente a los cuatro objetivos específicos:

- **Para OE1 (Requisitos):** Se utiliza Google Cloud Platform (GCP) como entorno unificado para la gestión del ciclo de vida del dato y la documentación de metadatos técnicos.
- **Para OE2 (Enfoque IA):** Vertex AI se selecciona por sus capacidades nativas de MLOps, permitiendo el entrenamiento, evaluación y versionado de modelos predictivos con trazabilidad de experimentos.
- **Para OE3 (Arquitectura):** Se implementa un *Data Warehouse* moderno con BigQuery y orquestación basada en eventos (Cloud Functions), garantizando escalabilidad y

desacoplamiento.

- **Para OE4 (Evaluación):** Looker Studio habilita la visualización interactiva de métricas de desempeño (MAPE) y negocio, facilitando la validación de utilidad por parte de los *stakeholders*.

### 2.7.1 EVALUACIÓN TÉCNICA COMPARATIVA (GCP VS. AWS VS. AZURE)

Para fundamentar la elección de la infraestructura, se realizó una evaluación de ingeniería comparativa entre GCP, AWS y Azure. A diferencia de una comparación comercial, este análisis pondera cuatro ejes técnicos verificables para el caso de uso (pronóstico *batch* farmacéutico): (1) Fricción de interoperabilidad, (2) Latencia y comportamiento en frío (*Cold Start*), (3) Controles de seguridad y gobernanza, y (4) Economía unitaria (*Unit Economics*).

**Tabla 18.** *Scorecard de Evaluación Técnica de Ecosistemas Cloud*

Eje de Evaluación	Google Cloud Platform (Seleccionada)	AWS (Ecosistema Analítico Serverless)	Microsoft Azure (ML Studio + Synapse)	Impacto en la Tesis (Criterio de Selección)
<b>Interoperabilidad (Fricción de Integración)</b>	<b>Alta Integración Nativa:</b> El flujo BigQuery -> Vertex AI reduce los pasos de ETL. Permite entrenamiento directo sobre el almacén sin ductos de replicación intermedios.	<b>Modular:</b> Arquitectura potente pero fragmentada; típicamente requiere orquestación explícita (AWS Glue/Data Pipeline) y movimiento de datos S3 <- Redshift.	<b>Ecosistema Corporativo:</b> Integración robusta en stack Microsoft (PowerBI/Dynamics), pero mayor complejidad para <i>pipelines</i> basados puramente en código abierto (Python).	La reducción de componentes intermedios minimiza el riesgo de fallo en la ingesta de datos y acelera el desarrollo del prototipo.
<b>Latencia y Elasticidad (SLO)</b>	<b>Serverless (Scale-to-Zero):</b> Cloud Run optimizado	<b>Opciones Flexibles:</b> AWS Lambda y Fargate son	<b>Enterprise Functions:</b> Escalado robusto en planes Premium. En	Para un proceso <i>batch</i> nocturno, la latencia ultra-

	<p>para contenedores.</p> <p><b>Riesgo:</b> Latencia variable por <i>Cold Start</i>. <b>Acción:</b> Se definirá un SLO de latencia p95 a validar empíricamente en fase piloto.</p>	<p>estándares de industria. La latencia de arranque depende críticamente del tamaño del paquete de despliegue y la configuración de VPC.</p>	<p>planes de consumo (<i>Consumption</i>), la variabilidad de latencia puede ser alta bajo cargas discontinuas.</p>	<p>baja no es crítica; se prioriza la capacidad de escalar a cero (costo nulo) sobre la velocidad de milisegundos.</p>
<p><b>Seguridad y Gobernanza</b></p>	<p><b>Cifrado por Defecto:</b> Encriptación en reposo/tránsito automático.</p> <p><b>Control:</b> IAM unificado.</p> <p><b>Cumplimiento:</b> Depende de configuración del cliente bajo el Modelo de Responsabilidad Compartida.</p>	<p><b>Granularidad:</b> IAM ofrece control extremadamente detallado, lo que eleva la complejidad de configuración inicial para asegurar el entorno ("Secure by Design").</p>	<p><b>Identidad:</b> Fortaleza en integración con Active Directory. Si no existe AD, la gestión de identidad añade sobrecarga administrativa innecesaria para la tesis.</p>	<p>El modelo de GCP facilita la implementación de controles base (cifrado, identidad) con menor esfuerzo de configuración inicial.</p>
<p><b>Modelo de Costos (OPEX)</b></p>	<p><b>Desacoplado:</b> BigQuery separa cobro de almacenamiento y cómputo (<i>slots</i>). Vertex AI y Cloud Run cobran por uso efectivo (segundos).</p>	<p><b>Instancia vs Consumo:</b> SageMaker ofrece ambos modelos. La optimización de costos requiere seleccionar la instancia correcta (<i>right-sizing</i>) para evitar sobreaprovisionamiento.</p>	<p><b>Capacidad Reservada:</b> Modelos de precios competitivos bajo contratos Enterprise, pero menos flexibles para cargas de trabajo pequeñas y aisladas (<i>Pay-as-you-go</i>).</p>	<p>La granularidad de facturación por segundo y la separación de costos en BigQuery son decisivas para la viabilidad financiera.</p>

*Nota.* Elaboración propia. La evaluación prioriza la simplicidad de integración y el modelo de costos flexible para cargas de trabajo discontinuas.

### 2.7.1.1 ANÁLISIS DE COSTOS UNITARIOS (UNIT ECONOMICS)

Para responder a la exigencia de comparabilidad financiera, se presenta el desglose de los *Unit Economics* para el escenario de inferencia. Este análisis normaliza la estructura de costos, permitiendo una comparación directa basada en unidades de consumo técnico.

**Tabla 19.** Comparativo de Unit Economics para Inferencia Serverless (GCP vs AWS)

<b>Componente de Costo</b>	<b>Unidad de Cobro (GCP - Cloud Run)</b>	<b>Unidad de Cobro (AWS - SageMaker Serverless)</b>	<b>Fórmula de Estimación de Costo (Escenario Batch)</b>
<b>Cómputo (Procesamiento)</b>	<b>vCPU-segundo + GB-segundo:</b> Facturación por recursos asignados durante el tiempo de procesamiento, redondeado a 100ms.	<b>Duración (ms) + Memoria Configurada:</b> Facturación por el tiempo de inferencia basado en la memoria aprovisionada (GB).	$C_{\text{comp}} = (N_{\text{pred}} \times T_{\text{avg}}) \times P_{\text{unit}}$ <p><i>Donde N es volumen, T es tiempo promedio y P tarifa por segundo.</i></p>
<b>Solicitudes (Requests)</b>	<b>Por millón de solicitudes:</b> Tarifa fija por invocación de la API (tras capa gratuita).	<b>N/A (Incluido):</b> Generalmente incluido en el costo de cómputo en modelos serverless específicos, o cobrado por invocación en Lambda.	$C_{\text{req}} = \frac{N_{\text{pred}}}{1,000,000} \times P_{\text{req}}$
<b>Transferencia de Datos (Red)</b>	<b>Intra-Región (Ingress/Egress):</b> Gratuito entre BigQuery, Vertex AI y Cloud Run en la misma región.	<b>Data Transfer:</b> Gratuito dentro de la misma AZ/Región para ciertos servicios; costo si cruza zonas o sale a	$C_{\text{net}} \rightarrow 0$ (Se minimiza bajo arquitectura regional unificada según política de tráfico interno).

		internet.	
--	--	-----------	--

*Nota.* Elaboración propia basada en documentación oficial de precios (Google Cloud, 2024; AWS, 2024). Este modelo confirma que, para cargas intermitentes, el costo es linealmente proporcional al uso, eliminando el desperdicio de recursos ociosos.

## 2.7.2 PLATAFORMA DE DESARROLLO ANALÍTICO

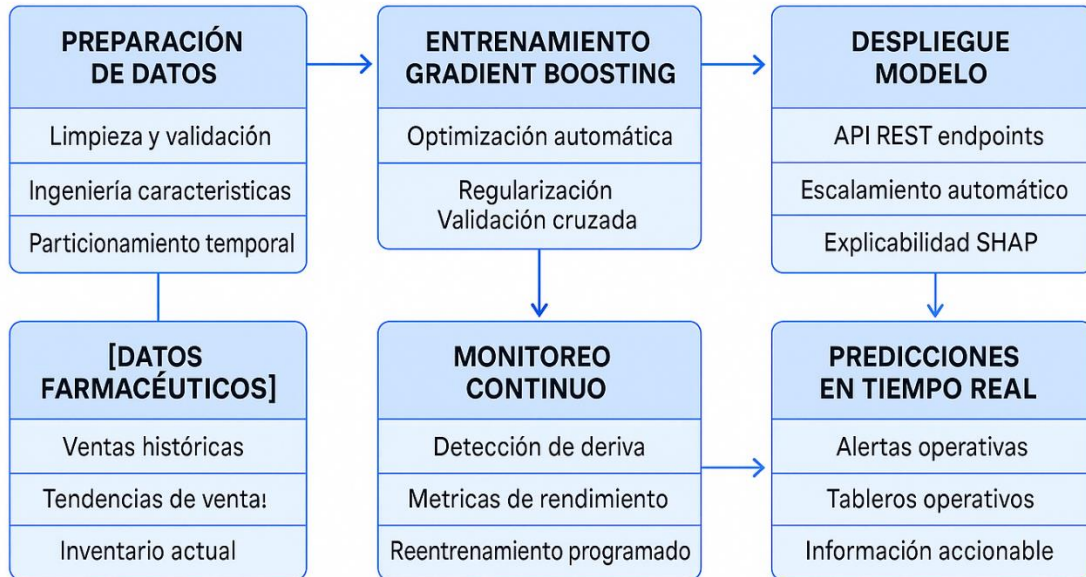
La arquitectura de solución se despliega sobre un ecosistema integrado en Google Cloud Platform, compuesto por: Vertex AI (núcleo de inteligencia), BigQuery (núcleo de datos), Cloud Functions y Pub/Sub (núcleo de integración), Cloud Run (inferencia serverless), Cloud Scheduler/Workflows (orquestración) y Cloud Monitoring (observabilidad).

### 2.7.2.1 VERTEX AI

Vertex AI constituye la plataforma central para desarrollar y validar modelos como gradient boosting. Su selección responde a características específicas que facilitan el desarrollo académico: capacidades AutoML que optimizan automáticamente hiperparámetros reduciendo requisitos de expertise técnica especializada, integración nativa con otros servicios Google Cloud que simplifica arquitecturas de datos, y disponibilidad de créditos académicos que hacen viable el desarrollo sin restricciones presupuestarias prohibitivas.

La plataforma incorpora Explainable AI para generar atribuciones de características y Model Monitoring para detección de deriva predictiva y sesgo, funcionalidades que requieren configuración explícita de esquemas de referencia, ventanas de monitoreo y umbrales de alerta para operación efectiva. Vertex AI está incluido en los servicios elegibles para cumplimiento HIPAA bajo Business Associate Agreement (BAA), aunque el cumplimiento efectivo requiere configuración apropiada de controles de seguridad y privacidad por parte del cliente organizacional. La integración nativa con BigQuery permite acceso directo a datos históricos estructurados sin transferencias complejas que introduzcan latencia o riesgos adicionales de seguridad.

## Arquitectura de Vertex AI para Pronóstico de Demanda Farmacéutica



**Ilustración 5.** *Arquitectura de Vertex AI para Pronóstico de Demanda Farmacéutica*

*Nota.* Elaboración propia de cómo la arquitectura prioriza simplicidad y eficiencia para desarrollo académico mientras mantiene escalabilidad conceptual para implementaciones futuras.

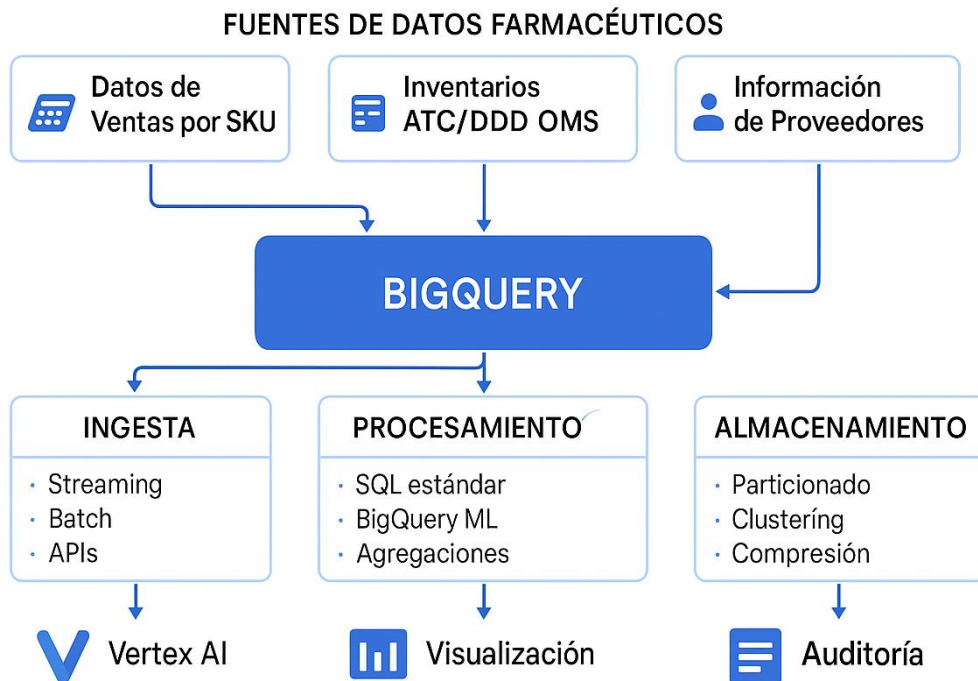
### 2.7.2.2 BIGQUERY

BigQuery funciona como almacén analítico centralizado que demuestra capacidades de consolidación de datos, procesando datos heterogéneos farmacéuticos mediante su arquitectura serverless y capacidades de procesamiento masivamente paralelo. Para el desarrollo del prototipo, centralizará datos históricos anonimizados del caso de estudio, complementados con datos sintéticos únicamente para pruebas de carga.

La funcionalidad BigQuery ML incorporada facilita validación de enfoques predictivos alternativos mediante SQL estándar, incluyendo capacidades para entrenar y evaluar modelos de gradient boosting directamente sobre datos estructurados, proporcionando flexibilidad para análisis comparativos que enriquezcan la evaluación metodológica (Google Cloud, 2024). Las

capacidades de particionamiento temporal optimizan consultas analíticas sobre series temporales históricas, mientras que clustering por categorías farmacológicas (ATC) acelera agregaciones por grupos terapéuticos específicos.

## Arquitectura BigQuery para Consolidación Informativa



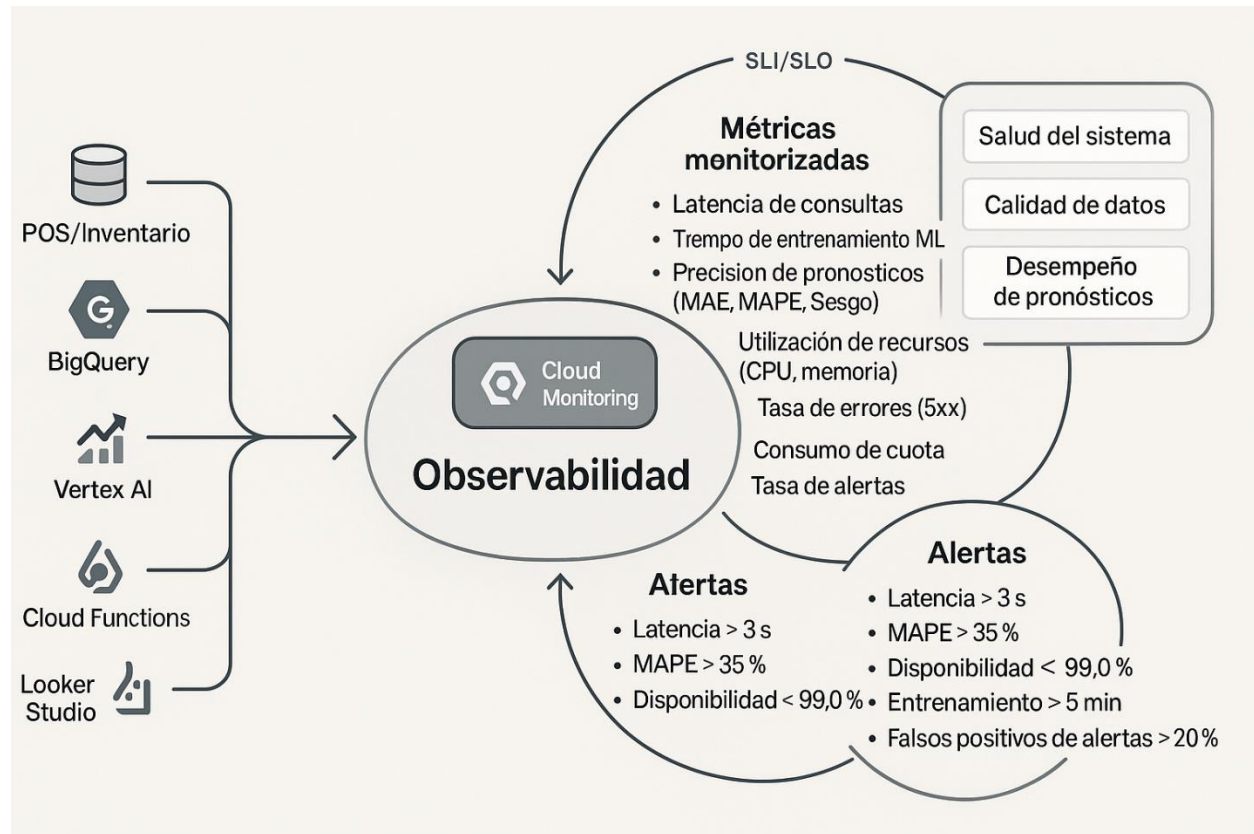
**Ilustración 6.** *Arquitectura BigQuery para Consolidación Informativa*

*Nota.* Elaboración propia de como la estructura optimiza tanto el desarrollo conceptual como la demostración de capacidades de consolidación informativa requerida.

### 2.7.2.3 HERRAMIENTAS DE OBSERVABILIDAD

Cloud Monitoring y Logging proporcionan capacidades de observabilidad que demuestran los requisitos de disponibilidad de datos, aunque en el contexto de desarrollo conceptual su función principal es documentar comportamientos del sistema y establecer líneas base para especificaciones operativas futuras.

Estas herramientas facilitarán el monitoreo de métricas críticas durante el desarrollo: latencia de consultas analíticas, precisión de pronósticos en validación cruzada, utilización de recursos computacionales, y patrones de acceso a datos. Los tableros personalizados documentarán el comportamiento del prototipo bajo diferentes condiciones de carga simulada, proporcionando evidencia empírica para las especificaciones de desempeño arquitectónico.



**Ilustración 7.** Sistema de Observabilidad Cloud Monitoring/Logging para Operaciones Farmacéuticas Críticas

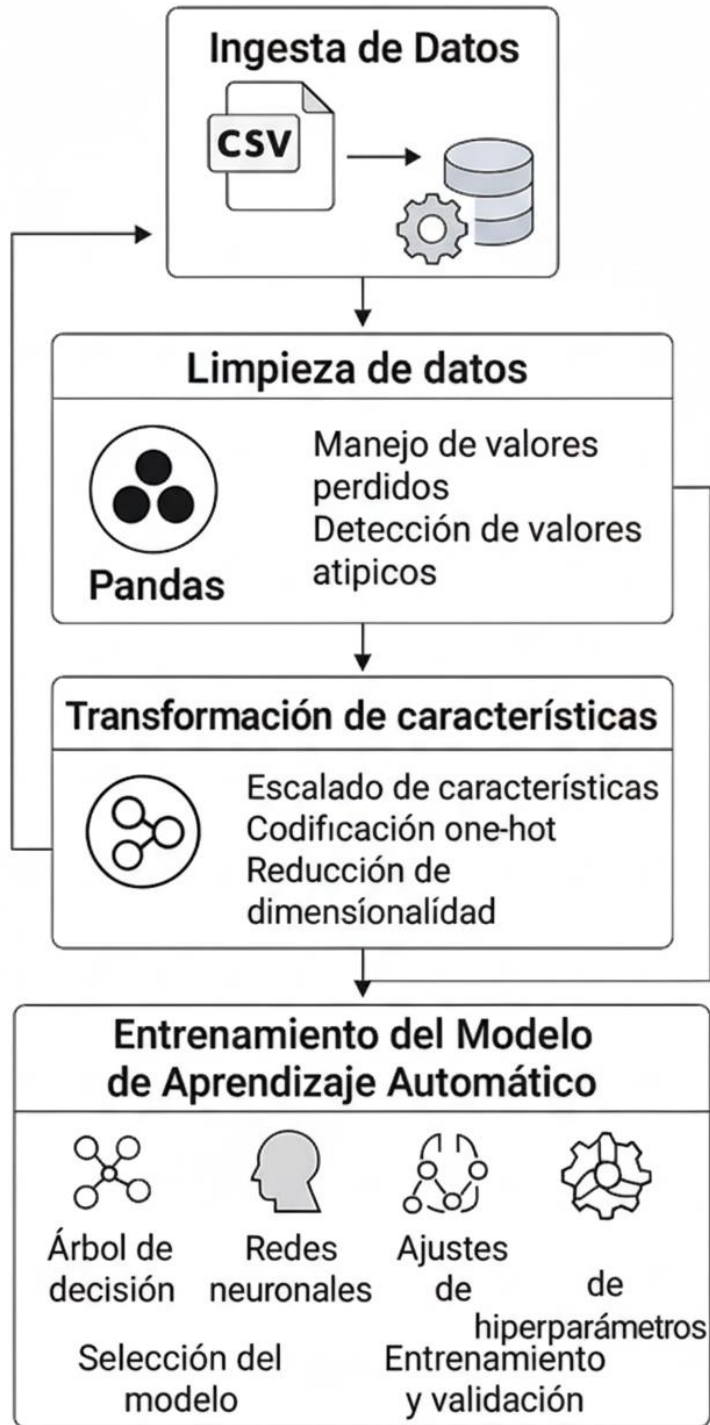
*Nota.* Elaboración propia de como el sistema de observabilidad proporciona visibilidad end-to-end de la salud operacional de la plataforma, permitiendo detección temprana de anomalías que podrían comprometer la disponibilidad de información crítica para gestión de medicamentos esenciales.

#### 2.7.2.4 PYTHON

Python se establece como el lenguaje de programación principal para la manipulación de datos, la ingeniería de características y el desarrollo de scripts personalizados que complementan las capacidades de la plataforma. Su ecosistema de bibliotecas de código abierto, como Pandas

para la estructuración de datos y Scikit-learn para tareas de preprocesamiento, es fundamental para preparar los conjuntos de datos farmacéuticos antes del entrenamiento de modelos. Géron (2022) establece que las bibliotecas como Scikit-learn proporcionan herramientas robustas para implementar algoritmos de gradient boosting, requiriendo validación cuidadosa para evitar sobreajuste en datos limitados, limitación relevante en contextos con información histórica acotada.

En el contexto de este proyecto, Python actúa como el pegamento programático que permite la orquestación de flujos de trabajo complejos, facilitando la extracción de datos desde BigQuery, su transformación en formatos adecuados y la interacción programática con las APIs de Vertex AI para el entrenamiento y la evaluación de los modelos gradient boosting, asegurando la reproducibilidad.

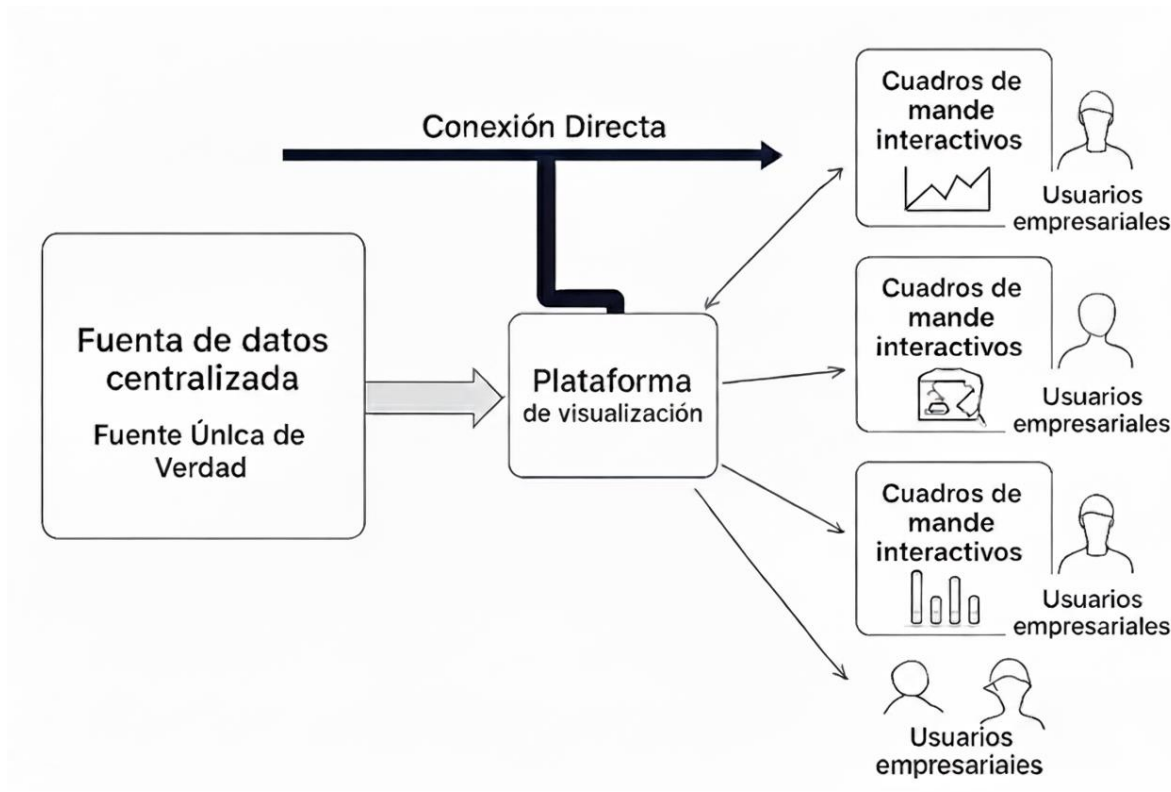


**Ilustración 8.** Flujo de Procesamiento de Datos con Python

*Nota.* Adaptado de Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow por A. Géron, 2022, O'Reilly. El diagrama ilustra el rol central de Python y sus bibliotecas para la ingesta, limpieza y transformación de datos brutos en características optimizadas para el entrenamiento de modelos de aprendizaje automático.

### 2.7.2.5 LOOKER STUDIO

Looker Studio es la herramienta de inteligencia de negocios seleccionada para la materialización de los tableros integrados. Su principal ventaja radica en su conector nativo y optimizado para BigQuery, lo que permite la creación de visualizaciones interactivas y reportes dinámicos directamente sobre el almacén de datos analíticos mediante consulta directa, sin necesidad de mover o duplicar la información. Las métricas de ventas, inventarios y pronósticos se actualizan de forma casi instantánea, sujetas a las políticas de caché y cuotas del conector BigQuery, proporcionando a los tomadores de decisiones una vista precisa y actualizada del estado de la cadena de suministro. La flexibilidad de Looker Studio para diseñar interfaces personalizadas facilita la creación de vistas específicas para diferentes roles operativos, desde el personal de farmacia hasta los gerentes de compras, cumpliendo con el objetivo de transformar datos consolidados en conocimiento visualmente intuitivo y accionable.



**Ilustración 9.** *Arquitectura de Visualización con Looker Studio y BigQuery*

*Nota.* El esquema muestra la conexión directa entre BigQuery como fuente única de verdad y Looker Studio como la capa de visualización, lo que permite a los usuarios explorar datos de manera interactiva para la toma de decisiones

informadas.

#### 2.7.2.6 CLOUD FUNCTIONS Y PUB/SUB

El sistema de alertas contextualizadas se implementa mediante una arquitectura event-driven (dirigida por eventos) utilizando Cloud Functions y Pub/Sub. En este modelo, Pub/Sub actúa como un servicio de mensajería asíncrono y escalable que desacopla los componentes del sistema. Diferentes eventos, como la finalización de un nuevo ciclo de pronósticos en Vertex AI o la detección de un nivel de inventario por debajo del umbral crítico en BigQuery, publican un mensaje en un "tema" de Pub/Sub. Cloud Functions, un servicio de cómputo sin servidor (serverless), se suscribe a estos temas y ejecuta automáticamente una función específica en respuesta a cada mensaje. Esta función contiene la lógica para enriquecer la alerta con contexto (ej. criticidad del medicamento, tiempo de reposición del proveedor) y enviarla al canal apropiado (ej. correo electrónico, notificación push), garantizando una respuesta oportuna y eficiente ante riesgos operativos.

## Modelo de Alertas Asíncronas



**Ilustración 10.** *Modelo de Alertas Asíncronas con Pub/Sub y Cloud Functions*

*Nota.* Adaptado del patrón de diseño Publisher-Subscriber descrito por G. Hohpe y B. Woolf en *Enterprise Integration Patterns* (2003), Addison-Wesley. La arquitectura desacopla a los productores de eventos de los consumidores, permitiendo un sistema de notificaciones resiliente y escalable.

### 2.7.2.7 ARQUITECTURA SERVERLESS

Para el desarrollo conceptual académico, se especifica una arquitectura completamente SERVERLESS que priorice simplicidad operativa y facilite la demostración de viabilidad técnica dentro del alcance de 19 semanas. Esta decisión arquitectónica responde específicamente a las restricciones del contexto académico y se alinea con principios de computación en la nube establecidos por Mell y Grance (2011).

Los componentes principales son:

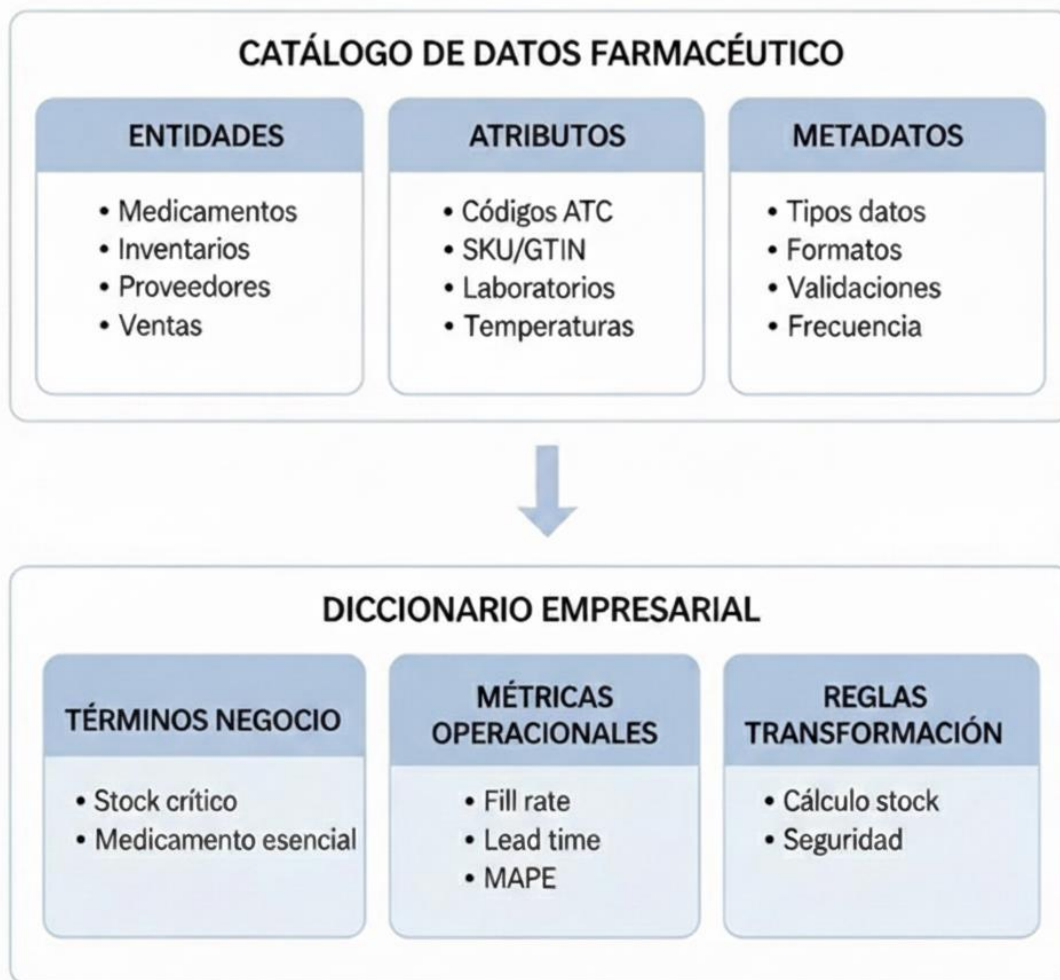
1. Cloud Run: Ejecución de contenedores sin servidor con escalado automático desde cero. Alojaría servicios de inferencia (modelo ML entrenado) para generar predicciones bajo demanda mediante API REST.
2. Cloud Scheduler: Orquestación automatizada de tareas periódicas sin infraestructura dedicada. Dispararía reentrenamiento semanal del modelo ML y actualización de predicciones cada 24 horas.
3. Cloud Workflows: Coordinación declarativa de procesos analíticos complejos mediante YAML. Orquestraría pipeline completo (ingesta → preparación → entrenamiento → evaluación → deployment) sin código de coordinación personalizado.

### 2.7.3 INSTRUMENTOS DE DOCUMENTACIÓN ARQUITECTÓNICA

Los instrumentos de arquitectura empresarial proporcionan estructura documental que facilita la comunicación de especificaciones técnicas a diferentes audiencias, desde evaluadores académicos hasta implementadores técnicos potenciales.

#### 2.7.3.1 CATÁLOGO DE DATOS Y DICCIONARIO EMPRESARIAL

El catálogo documentará exhaustivamente todas las estructuras de datos necesarias para la plataforma farmacéutica digital, estableciendo definiciones estandarizadas que faciliten interpretación consistente: SKUs de medicamentos con códigos únicos, clasificaciones ATC OMS con jerarquías completas, categorías por laboratorio y temperatura de almacenamiento, y niveles de criticidad operacional basados en impacto clínico. La documentación incluirá metadatos técnicos esenciales: tipos de datos optimizados para consultas analíticas, formatos estandarizados que faciliten intercambio, rangos de valores válidos que soporten validación automática, y frecuencias de actualización requeridas para mantener coherencia informacional.



**Ilustración 11.** Estructura del Catálogo de Datos y Diccionario Empresarial Farmacéutico

*Nota.* Elaboración propia de como la estructura del catálogo y diccionario asegura interpretación consistente de información crítica farmacéutica entre diferentes sistemas y usuarios, proporcionando la base semántica necesaria para consolidación efectiva de datos dispersos en vistas informacionales unificadas.

### 2.7.3.2 MATRIZ DE TRAZABILIDAD

La matriz establecerá relaciones explícitas y bidireccionales entre cada requisito funcional y no funcional con los componentes arquitectónicos específicos que los implementan, facilitando validación de completitud conceptual y análisis de impacto ante evoluciones futuras.

**Tabla 20.** *Matriz de Trazabilidad Requisitos-Componentes Técnicos*

<b>Objetivo Específico</b>	<b>Categoría Tecnológica</b>	<b>Herramientas Seleccionadas</b>	<b>Justificación Conceptual</b>
<b>OE1: Requisitos</b>	Documentación y validación	Catálogo de datos + Instrumentos mixtos	Estructuración sistemática de requisitos
<b>OE2: Enfoque IA</b>	Aprendizaje automático	Vertex AI + Python	Gradient boosting con explicabilidad
<b>OE3: Arquitectura</b>	Infraestructura cloud	BigQuery + Servicios serverless	Escalabilidad y disponibilidad conceptual
<b>OE4: Evaluación</b>	Visualización y análisis	Looker Studio + Métricas validación	Evaluación integral de viabilidad

*Nota.* La selección tecnológica se fundamenta en principios de computación en la nube y capacidades de demostración académica.

Esta estructura de herramientas e instrumentos facilita el desarrollo conceptual completo dentro de las limitaciones académicas, manteniendo rigor técnico suficiente para demostrar viabilidad práctica de los enfoques propuestos mientras genera especificaciones utilizables para implementaciones operativas futuras. Es importante destacar que esta selección tecnológica responde específicamente al contexto académico del proyecto, priorizando la demostración de viabilidad conceptual sobre la implementación operativa. Las herramientas seleccionadas facilitan el desarrollo de prototipos funcionales dentro de las limitaciones presupuestarias y temporales del estudio, manteniendo escalabilidad conceptual para futuras implementaciones sin comprometer el rigor metodológico requerido para responder a las preguntas de investigación planteadas.

## 2.8 CONCEPTUALIZACIÓN

La conceptualización establece las definiciones técnicas y operacionales que fundamentan el modelo de información con capacidades predictivas propuesto, proporcionando claridad terminológica esencial para la comprensión integral del proyecto. Estas definiciones se alinean específicamente con los objetivos planteados y los componentes técnicos desarrollados, facilitando

interpretación consistente de conceptos especializados por parte de evaluadores e implementadores potenciales. Como indica el Manual de Fondo, esta sección prioriza la relación y contraste entre conceptos, evitando un glosario simple; por ejemplo, contrastando enfoques predictivos tradicionales con avanzados para resaltar evolución en contextos farmacéuticos limitados.

**Cadena de Suministro Farmacéutica:** Sistema interconectado que engloba el flujo de medicamentos desde fabricación hasta dispensación, incluyendo procesos de adquisición, almacenamiento, distribución y control de inventarios. En el contexto de este proyecto, representa el ecosistema operativo donde la plataforma digital generará información para optimizar decisiones de reposición. La literatura reciente contrasta esta cadena con modelos tradicionales, destacando cómo disrupciones logísticas requieren sistemas proactivos para mitigar impactos, a diferencia de enfoques reactivos que agravan quiebres (Shukar et al., 2021).

**Medicamentos Esenciales:** Productos farmacéuticos que satisfacen necesidades prioritarias de atención médica poblacional, definidos según criterios de la OMS que incluyen relevancia clínica, seguridad comprobada y costo-efectividad. La plataforma priorizará estos productos en algoritmos de alerta temprana y asignación de recursos predictivos. World Health Organization (2025) enfatiza su rol en equidad de acceso, contrastando con medicamentos no esenciales donde la disponibilidad es menos crítica para salud pública.

**Analítica Predictiva Farmacéutica:** Aplicación de técnicas de aprendizaje automático específicamente adaptadas para identificar patrones en datos de demanda farmacéutica y generar pronósticos con intervalos de confianza asociados. Incluye consideraciones especiales para volatilidad estacional, efectos promocionales y variabilidad epidemiológica característica del sector farmacéutico. Nguyen et al. (2022) contrastan esta analítica con métodos descriptivos, señalando que predictivos permiten anticipación proactiva, superando limitaciones reactivas en cadenas volátiles.

**Plataforma Digital Integrada:** Ecosistema tecnológico que consolida datos operativos dispersos en interfaces unificadas, proporcionando capacidades analíticas avanzadas mediante servicios especializados de aprendizaje automático, tableros interactivos y sistemas de alertas contextualizadas. Organización Panamericana de la Salud [OPS] (2024) relaciona este concepto con transformación digital, contrastando plataformas integradas con sistemas fragmentados que

generan ineficiencias en salud.

**Familia de Algoritmos Gradient Boosting para Contextos Farmacéuticos:** Implementación especializada de algoritmos de gradient boosting optimizada para datos farmacéuticos caracterizados por series temporales cortas, alta variabilidad y necesidades de interpretabilidad. Incluye adaptaciones para agrupación inteligente por categorías ATC/DDD OMS y generación de scores de importancia para explicabilidad de alertas contextualizadas con trazabilidad regulatoria.

**Quiebre de Stock:** Situación crítica donde la demanda supera el inventario disponible, resultando en impacto directo sobre continuidad de tratamientos y satisfacción del paciente. La plataforma identifica riesgos de quiebre mediante análisis predictivo con horizontes de 14 días, permitiendo intervención preventiva. El USAID Global Health Supply Chain Program – Procurement and Supply Management (2024) contrasta quiebres prevenibles con inevitables, enfatizando que los sistemas de alerta temprana pueden transformar impactos negativos en oportunidades de mejora.

**Visibilidad Integrada de Inventarios:** Capacidad informacional que elimina fragmentación de datos mediante consolidación de información de ventas, stocks y vencimientos en vistas unificadas actualizadas en tiempo real. Lugada et al. (2022) relaciona esta visibilidad con fortalecimiento de sistemas, contrastando con silos informacionales que perpetúan ineficiencias en cadenas de suministro.

**Alertas Predictivas Contextualizadas:** Notificaciones automatizadas que combinan análisis de riesgo cuantitativo con información contextual relevante (categoría terapéutica, criticidad clínica, plazos de reposición), diseñadas para facilitar decisiones preventivas efectivas. El National Institute of Standards and Technology (2023) subraya que la interpretabilidad y la explicabilidad son características clave de los sistemas de inteligencia artificial confiables, lo que respalda el diseño de alertas transparentes que faciliten su adopción por parte de los usuarios.

**TOGAF ADM Farmacéutico:** Adaptación del Architecture Development Method para contextos sanitarios que integra consideraciones de cumplimiento regulatorio, interoperabilidad con sistemas de salud y seguridad de datos sensibles. Estructura la especificación técnica que

responde al Objetivo Específico 3 mediante dominios de negocio, datos, aplicaciones y tecnología coherentemente alineados. The Open Group (2022) define este método iterativo como el estándar para el desarrollo de arquitecturas empresariales, resaltando su flexibilidad para entornos regulados.

**Gestión Informacional:** Paradigma que transforma datos transaccionales dispersos en conocimiento accionable mediante un flujo técnico automatizado en Google Cloud Platform. En el contexto específico de este proyecto, la gestión informacional no es un concepto abstracto, sino un proceso ingenieril trazable que se operacionaliza así: (1) Ingesta y Consolidación: BigQuery centraliza datos heterogéneos (ventas, stock, maestro de productos) eliminando silos; (2) Enriquecimiento Cognitivo: Vertex AI aplica modelos de *Gradient Boosting* sobre estos datos consolidados para generar nuevas variables de valor (pronósticos de demanda, probabilidad de quiebre); y (3) Activación: Los resultados se devuelven a la operación mediante alertas en Cloud Functions y tableros en Looker Studio. Esta definición contrasta con la gestión de datos tradicional (pasiva y descriptiva) al incorporar un componente activo de inteligencia artificial que modifica la toma de decisiones en tiempo real (ISACA, 2019).

**Backtesting Farmacéutico:** Metodología de validación que evalúa precisión de modelos predictivos mediante simulación retrospectiva con datos históricos conocidos, permitiendo cuantificar confiabilidad de pronósticos antes de implementación operativa. Hyndman y Athanasopoulos (2021) contrasta backtesting con validación forward, enfatizando su utilidad para datos limitados, aunque subestima dinámicas futuras.

**Computación en la Nube Farmacéutica:** Infraestructura tecnológica que proporciona recursos computacionales escalables, almacenamiento seguro y servicios especializados accesibles remotamente, caracterizada por elasticidad de recursos, cumplimiento regulatorio sanitario y capacidades de integración con sistemas hospitalarios existentes. Mell y Grance (2011) definen la computación en la nube como “un modelo para habilitar el acceso ubicuo, conveniente y bajo demanda, a través de la red, a un conjunto compartido de recursos de TI configurables” (p. 2), lo que contrasta con enfoques on-premise por su mayor elasticidad.

**MAPE (Error Porcentual Absoluto Medio):** Métrica de precisión predictiva que cuantifica el error promedio de un modelo como porcentaje de los valores reales, calculada como

$(100/n) \times \sum |((y_{\text{real}} - y_{\text{predicho}})/y_{\text{real}})|$ . En contextos farmacéuticos, Hyndman y Athanasopoulos (2021) advierten que MAPE presenta limitaciones cuando los valores reales son cercanos a cero, contrastando con MAE, que mantiene robustez en dichas condiciones.

**Horizonte de Predicción:** Período futuro para el cual se generan pronósticos de demanda, expresado en días desde el momento del análisis. En la práctica, los horizontes más cortos suelen asociarse con mayor precisión, pero menor capacidad de planificación, mientras que horizontes más largos permiten decisiones estratégicas con un costo potencial en exactitud (Hyndman & Athanasopoulos, 2021).

**Alerta Accionable:** Notificación predictiva que cumple criterios operativos mínimos para habilitar una decisión concreta, tales como anticipación suficiente frente al tiempo de reposición, superación de umbrales críticos de stock, nivel razonable de confianza estadística, viabilidad logística de la acción sugerida y ausencia de duplicidad innecesaria de notificaciones. Este concepto contrasta alertas meramente informativas con aquellas que facilitan decisiones preventivas efectivas.

**Validación Temporal Walk-forward:** Metodología de evaluación que simula condiciones operativas reales mediante entrenamiento secuencial del modelo con ventanas temporales progresivas, preservando el orden cronológico de datos para evitar filtración de información futura (data leakage). A diferencia de validación cruzada tradicional que mezcla temporalidades, walk-forward respeta la causalidad temporal inherente a series farmacéuticas, donde el futuro no puede informar predicciones del pasado. Específicamente, el esquema implementado entrena el modelo con períodos acumulativos crecientes (ejemplo: días 1-60 para predecir día 61, luego días 1-67 para predecir día 68, sucesivamente hasta agotar conjunto de prueba), generando múltiples evaluaciones que cuantifican precisión promedio y variabilidad bajo condiciones realistas de pronóstico recurrente. Hyndman y Athanasopoulos (2021) contrastan este enfoque con time series cross-validation que permite múltiples ventanas solapadas, destacando que walk-forward simple resulta más apropiado para datos limitados donde validación exhaustiva agotaría el conjunto de entrenamiento disponible, comprometiendo la capacidad del modelo para capturar patrones estacionales.

## 2.9 MARCO LEGAL

El marco legal establece el contexto normativo que legitima y condiciona el desarrollo del modelo de información con capacidades predictivas propuesto, definiendo tanto las oportunidades regulatorias como las restricciones de cumplimiento que deben integrarse en el diseño técnico. Esta estructura jurídica garantiza que la solución tecnológica opere dentro de parámetros legales apropiados mientras aprovecha marcos habilitantes para innovación en salud digital. La convergencia entre normativas internacionales de salud digital e inteligencia artificial ética con el marco regulatorio nacional hondureño crea un ecosistema jurídico específico que debe ser navegado estratégicamente para maximizar viabilidad técnica y comercial del proyecto. Sin embargo, se identifica un vacío en regulación específica para IA en salud en Honduras, lo que podría generar contradicciones interpretativas en implementación, sugiriendo líneas para armonización con estándares internacionales.

### 2.9.1 MARCO LEGAL INTERNACIONAL

#### 2.9.1.1 ESTÁNDARES DE SALUD DIGITAL

La Lista Modelo de Medicamentos Esenciales de la OMS 2025 proporciona el referente técnico fundamental para clasificación y priorización de medicamentos en sistemas analíticos farmacéuticos. World Health Organization (2025) define medicamentos esenciales como aquellos que satisfacen las necesidades prioritarias de atención sanitaria de la población, estableciendo criterios específicos que deben incorporarse en modelos predictivos para asegurar que las capacidades analíticas prioricen productos de mayor impacto en salud pública. Esta clasificación internacional facilita la implementación de taxonomías estandarizadas que optimizan agrupaciones por categorías ATC/DDD OMS en algoritmos de aprendizaje automático, asegurando que productos de alta criticidad clínica reciban tratamiento predictivo diferenciado según criterios reconocidos internacionalmente.

El Plan de Acción IS4H 2024-2030 de la Organización Panamericana de la Salud legitima iniciativas de digitalización farmacéutica al establecer que los Estados deben fortalecer la gestión y la gobernanza de los sistemas de información para la salud (Organización Panamericana de la Salud [OPS], 2024). Este mandato regional proporciona respaldo institucional para proyectos que

mejoren la disponibilidad de medicamentos mediante tecnologías de información, creando un contexto favorable para implementación y escalamiento de soluciones analíticas.

Los Estándares GS1 Healthcare para trazabilidad farmacéutica definen protocolos técnicos de identificación única y seguimiento que las plataformas digitales deben soportar para asegurar interoperabilidad futura con sistemas hospitalarios y de cadena de suministro nacional. Estos estándares especifican formatos de codificación y estructuras de datos que deben considerarse en el diseño de sistemas de información farmacéutica para facilitar cumplimiento automático.

#### 2.9.1.2 FRAMEWORKS DE IA ÉTICA

El NIST AI Risk Management Framework 1.0 establece principios para desarrollo responsable de sistemas de inteligencia artificial que deben integrarse en el diseño de algoritmos predictivos farmacéuticos. National Institute of Standards and Technology (2023) establece principios de interpretabilidad y explicabilidad para sistemas de inteligencia artificial confiables, mandato que se materializa en la selección de algoritmos con capacidades nativas de explicabilidad mediante métricas de importancia de características. Este framework proporciona metodologías específicas para generar alertas contextualizadas que incluyan explicaciones comprensibles sobre las razones algorítmicas que sustentan cada notificación de riesgo, aspecto fundamental para la aceptación de sistemas predictivos en contextos farmacéuticos críticos.

Las Recomendaciones sobre Ética de la Inteligencia Artificial de la UNESCO establecen principios fundamentales que deben guiar el desarrollo de plataformas farmacéuticas: transparencia algorítmica que permita auditoría de decisiones automatizadas, supervisión humana que mantenga control final sobre decisiones críticas, y equidad que asegure tratamiento balanceado de todas las categorías de medicamentos sin sesgo sistemático hacia productos de mayor volumen. UNESCO (2021) enfatiza estos valores para promover derechos humanos.

**Tabla 21. Comparación de Marcos Regulatorios de IA en Salud (Internacional)**

<b>Jurisdicción</b>	<b>Marco Legal</b>	<b>Requisitos Clave</b>	<b>Aplicabilidad Honduras</b>
<b>Unión Europea</b>	AI Act 2024	Clasificación por riesgo (bajo/medio/alto/inaceptable); sistemas de salud = alto riesgo; auditorías obligatorias	No aplicable directamente, pero proporciona mejores prácticas aspiracionales
<b>Estados Unidos</b>	FDA Software as Medical Device (SaMD)	Distinción entre dispositivo médico vs herramienta administrativa; validación clínica para SaMD	Útil para clasificación conceptual del sistema propuesto
<b>OMS/OPS</b>	Principios éticos de IA en salud (2021)	Transparencia, explicabilidad, supervisión humana, equidad	Directamente aplicables; alineados con la ausencia de regulación específica hondureña
<b>NIST (EE. UU.)</b>	AI Risk Management Framework 1.0	Gestión de riesgos, interpretabilidad, gobernanza	Marco técnico adoptado voluntariamente en este estudio
<b>UNESCO</b>	Recomendaciones sobre ética de IA	Derechos humanos, transparencia, supervisión humana	Principios éticos aplicables universalmente

*Nota.* En ausencia de un marco regulatorio específico hondureño para IA en salud, estos marcos internacionales proporcionan guías voluntarias adoptadas en el diseño conceptual del modelo propuesto, priorizando NIST AI RMF (aplicabilidad técnica) y UNESCO (enfoque ético).

### 2.9.1.3 MARCO DE PROTECCIÓN DE DATOS Y HABEAS DATA

Aunque Honduras carece de una Ley de Protección de Datos Personales autónoma equivalente al GDPR europeo, el derecho a la autodeterminación informativa (Habeas Data) está garantizado constitucionalmente y regulado por la Ley de Transparencia y Acceso a la Información Pública (Decreto 170-2006). El Artículo 3 (numeral 7) y el Artículo 10 de dicho decreto clasifican

como 'Datos Personales Confidenciales' aquellos referentes a la salud física o mental de las personas. En consecuencia, cualquier script o algoritmo utilizado en este proyecto debe operar bajo el principio de minimización de datos: los modelos predictivos procesarán únicamente variables transaccionales anonimizadas (SKU, fecha, cantidad), excluyendo explícitamente identificadores de pacientes (Nombres, DNI, Expediente Clínico) para garantizar el cumplimiento irrestricto de la confidencialidad sanitaria.

## 2.9.2 MARCO LEGAL NACIONAL

### 2.9.2.1 REGULACIÓN FARMACÉUTICA OPERATIVA

La Constitución de Honduras (artículos 145-150) establece el derecho fundamental a protección de la salud, proporcionando legitimidad jurídica para iniciativas que optimicen el acceso a medicamentos esenciales mediante innovación tecnológica. Este mandato constitucional respalda la implementación de sistemas que mejoren la eficiencia de gestión informacional farmacéutica en el sector privado como complemento al sistema público.

El Código de Salud (Decreto 65-1991) establece responsabilidades específicas para establecimientos farmacéuticos que las plataformas informacionales deben facilitar mediante funcionalidades de cumplimiento automático: documentación de transacciones para auditorías regulatorias, y reportes de farmacovigilancia que pueden sistematizarse mediante integración con bases de datos institucionales. Este marco normativo, al operacionalizarse mediante sistemas informacionales avanzados, contribuye directamente a la mitigación de riesgos de quiebres de stock.

La Lista Nacional de Medicamentos Esenciales de Honduras (LNME 2023-2025) constituye el marco normativo que define productos prioritarios para el sistema sanitario nacional. La Secretaría de Estado en el Despacho de Salud (2024), mediante el Acuerdo No. 5230-2023, indica que los medicamentos incluidos en la LNME representan aquellos de mayor impacto para la salud pública hondureña, seleccionados con base en criterios de eficacia, seguridad, calidad y costo-efectividad. Para operacionalizar esta priorización en modelos predictivos, el sistema propuesto integra la clasificación internacional ATC/DDD de la OMS como taxonomía técnica estandarizada, permitiendo que medicamentos de la LNME sean categorizados según su grupo

Anatómico, Terapéutico y Químico (ATC) con sus Dosis Diarias Definidas (DDD) correspondientes. Esta convergencia LNME-ATC/DDD facilita tanto el cumplimiento regulatorio nacional como la interoperabilidad con sistemas internacionales, asegurando que los algoritmos de aprendizaje automático puedan agrupar inteligentemente medicamentos por categorías terapéuticas mientras mantienen la priorización diferencial establecida por la normativa hondureña.

La Agencia de Regulación Sanitaria (ARSA), mediante sus lineamientos técnicos vigentes, requiere que los sistemas de gestión farmacéutica mantengan registros auditables que permitan trazabilidad completa de medicamentos. La adopción del sistema de clasificación ATC/DDD OMS facilita el cumplimiento automatizado de estos requisitos.

*ANÁLISIS DE CUMPLIMIENTO TÉCNICO-LEGAL (SCRIPT PYTHON VS. ACUERDO 0418-ARSA-2023): El Reglamento para el Control Sanitario (Acuerdo 0418-ARSA-2023) establece en sus artículos referentes a la vigilancia y control la obligatoriedad de garantizar la confidencialidad e integridad de la información sanitaria gestionada. Para dar respuesta estricta a este mandato mediante la solución tecnológica propuesta, se ha diseñado el script de procesamiento en Python (implementado en Vertex AI) bajo el principio de 'Privacidad por Diseño' (Privacy by Design), cumpliendo con tres controles de seguridad que satisfacen la normativa:*

- **Desacoplamiento de Identidad:** El script de Python no tiene acceso a las tablas de clientes o pacientes. El *pipeline* de datos en BigQuery realiza una vista materializada que agrega las ventas por SKU y Sucursal antes de que el script de IA las lea. Por tanto, el algoritmo procesa patrones de demanda agregada, no historiales clínicos individuales, eliminando el riesgo de violación de confidencialidad.
- **Ejecución Efímera y Encriptada:** El entorno de ejecución en la nube (Cloud Run/Vertex AI) es efímero y stateless. Los datos procesados en la memoria RAM del contenedor Python están cifrados y se destruyen al finalizar la inferencia, minimizando el riesgo de persistencia de 'logs' residuales mediante configuración de retención efímera y sanitización de salida.

- **Trazabilidad de Cambios (Audit Logs):** Aunque el script es automatizado, cada ejecución queda registrada en Cloud Logging, permitiendo auditar qué proceso accedió a qué datos y cuándo, cumpliendo con el requisito de trazabilidad operativa exigido por la autoridad sanitaria.

### 2.9.2.2 HABILITADORES DE GOBIERNO DIGITAL

La Ley de Firma Electrónica (149-2013) proporciona el marco jurídico para autenticación digital y validez de documentos electrónicos en procesos críticos de plataformas farmacéuticas. Esta ley habilita procesos completamente digitales para aprobación de pedidos, autorización de transferencias entre sucursales y firma de reportes regulatorios, reduciendo fricción operativa mientras mantiene validez jurídica completa.

La Hoja de Ruta para Transformación Digital del Sector Salud establece lineamientos estratégicos que crean contexto favorable para iniciativas analíticas. La Secretaría de Salud de Honduras (2024) promueve específicamente el fortalecimiento de sistemas de información integrados y la adopción de tecnologías emergentes para mejorar la eficiencia operativa, proporcionando alineación directa con objetivos gubernamentales de modernización sanitaria. Esta convergencia normativa facilita integración futura con sistemas públicos de salud para intercambio de información epidemiológica que podría enriquecer significativamente las capacidades predictivas de plataformas analíticas mediante incorporación de variables exógenas contextualmente relevantes.

**Tabla 22.** *Marco Legal Específico para Plataformas Farmacéuticas Digitales*

<b>Normativa Nacional</b>	<b>Ámbito de Aplicación</b>	<b>Requisito de Cumplimiento</b>	<b>Consideración Técnica</b>	<b>Impacto en Objetivos</b>
<b>LNME Honduras 2023-2025</b>	Algoritmos predictivos (OE2)	Priorización medicamentos esenciales	Ponderación diferencial por criticidad nacional	OE2: Agrupación ATC/DDD alineada con LNME

<b>Lineamientos ARSA-LT-2024-01</b>	Sistemas de monitoreo (OE3)	Reportes mensuales disponibilidad	Generación automática de reportes estructurados	OE3: Arquitectura debe incluir módulo de reporting regulatorio
<b>Reglamento General Control Sanitario (Acuerdo 0418-ARSA-2023)</b>	Vigilancia sanitaria (OE3)	Registros auditables de calidad	Anonimización en scripts Python y cifrado en memoria	OE2/OE3: El algoritmo procesa datos agregados (no PII) garantizando confidencialidad (Privacy by Design).
<b>Normativa ARSA PCM-008-2016</b>	Procesos regulatorios (OE1)	Facilitar inspecciones	Sistemas de cumplimiento automatizado	OE1: Requisito no funcional de auditoría (RNF-007)
<b>Ley Firma Electrónica 149-2013</b>	Procesos de aprobación (OE3)	Autenticación digital válida	Certificados PKI integrados	OE3: Componente de autenticación en arquitectura (IAM + Cloud KMS)

*Nota.* La tabla establece conexiones entre normativas aplicables y consideraciones técnicas específicas para implementación de cumplimiento por diseño.

### 2.9.3 IMPLICACIONES PARA DISEÑO TÉCNICO

El análisis del marco legal revela tres implicaciones críticas para el diseño conceptual de plataformas farmacéuticas digitales:

**Cumplimiento por Diseño:** Las funcionalidades de cumplimiento regulatorio deben integrarse nativamente en especificaciones arquitectónicas en lugar de añadirse posteriormente, requiriendo que servicios de logging, auditoría y reportes sean componentes fundamentales de marcos arquitectónicos empresariales aplicados al contexto farmacéutico.

**Interoperabilidad Estratégica:** El cumplimiento con estándares internacionales como HL7 FHIR y GS1 Healthcare debe considerarse desde la especificación conceptual de modelos de datos, facilitando integración futura con ecosistemas sanitarios nacionales e internacionales sin requerir rediseños arquitectónicos significativos.

**Transparencia Algorítmica:** Los requisitos de explicabilidad establecidos por marcos de IA ética deben materializarse en especificaciones de interfaces que traduzcan métricas técnicas de importancia de características en explicaciones comprensibles para usuarios farmacéuticos, asegurando que la sofisticación técnica no comprometa la usabilidad práctica.

Esta convergencia normativa crea un contexto altamente favorable para el desarrollo de modelos informacionales predictivos, proporcionando legitimidad jurídica, respaldo institucional y marcos técnicos específicos que facilitan tanto el cumplimiento regulatorio como la viabilidad conceptual de iniciativas analíticas en contextos farmacéuticos hondureños.

## CAPÍTULO III. METODOLOGÍA DE LA INVESTIGACIÓN

### 3.1 ENFOQUE

El estudio adopta un Enfoque Mixto con Diseño Exploratorio Secuencial (DEXPLOS) (Creswell & Plano Clark, 2017). Esta decisión metodológica responde a la naturaleza del problema: transformar conocimiento operativo (reglas/heurísticas de reposición y restricciones del entorno) en insumos computables para construir y validar un modelo predictivo aplicable a la gestión de inventarios de medicamentos esenciales.

Bajo este esquema, la investigación se desarrolla en dos fases secuenciales:

- **Fase cualitativa (QUAL – OE1):** especifica el dominio (qué medir y qué reglas deben respetarse), mediante instrumentos aplicados al personal clave y revisión documental del proceso.
- **Fase cuantitativa (QUAN – OE2–OE4):** valida empíricamente la capacidad predictiva y la utilidad operativa del modelo mediante **backtesting** con validación temporal.

La integración QUAL→QUAN se operacionaliza mediante ingeniería de características y parametrización de reglas de decisión (alertas). En la fase QUAN, esta integración se valida con una prueba de hipótesis cuantificada (Wilcoxon,  $\alpha=0.05$ ) sobre diferencias de error por SKU (sección 3.1.3.c), verificando que el modelo propuesto reduce el error respecto a la línea base.

#### 3.1.1 FASE 1: CUALITATIVA - ESPECIFICACIÓN DEL DOMINIO (QUAL)

La primera etapa corresponde a un alcance descriptivo-aplicado orientado a ingeniería (OE1). Su propósito es externalizar conocimiento tácito del personal responsable de la reposición y convertirlo en reglas de negocio computables y requisitos verificables.

Para ello se utilizaron:

1. **Análisis documental** del flujo de reposición y restricciones operativas del caso.
2. **Instrumento estructurado aplicado a actores clave (n=3)** para capturar:

- criterios de reposición y priorización (heurísticas),
- restricciones tecnológicas mínimas (habilitadores),
- percepción de utilidad de funciones del modelo (requisitos funcionales).

A diferencia de un estudio cualitativo interpretativo, aquí el objetivo no es construir categorías abstractas, sino extraer reglas y parámetros operativos (p. ej., criterios de reposición, tolerancias de lead time, umbrales de stock, condiciones mínimas de datos e infraestructura). Se precisa que este alcance descriptivo aplica solo a la fase QUAL (OE1); el estudio completo se clasifica como predictivo no experimental (ver sección 3.2) con diseño longitudinal retrospectivo (ver sección 3.3).

### 3.1.2 MECANISMO DE INTEGRACIÓN: INGENIERÍA DE CARACTERÍSTICAS

La integración entre fases se realiza mediante una **Matriz de Trazabilidad QUAL–QUAN**, donde los hallazgos cualitativos se convierten en:

- **(a) Variables predictoras (features)** para entrenamiento del modelo (OE2).
- **(b) Parámetros de decisión** para configurar reglas de alertas post-pronóstico (OE4).

**Tabla 23.** *Matriz de Integración Metodológica (DEXPLOS): Del Hallazgo Cualitativo a la Variable Operativa*

Hallazgo (heurística/condición)	Transformación (feature / parámetro)	Fuente y disponibilidad	Uso (modelo o regla)
<b>Estacionalidad operativa (variación por calendario)</b>	Variables calendario derivables de fecha (p.	Dataset transaccional: derivación directa	<b>Feature</b> del pronóstico: captura patrones

	ej., <i>day_of_week</i> , <i>month</i> , <i>is_weekend</i> )	desde campo de fecha	semanales/mensuales sin requerir variables externas
<b>Inercia de consumo reciente</b>	Rezagos y promedios móviles (p. ej., <i>lags</i> 7/14/28; <i>medias móviles</i> 7/14/30)	Dataset: cálculo sobre la serie de ventas por SKU	<b>Feature</b> del pronóstico: modela autocorrelación y dinámica de corto plazo
<b>Diferenciación de criticidad (esenciales vs no esenciales)</b>	Clasificación por campos <i>es_esencial</i> y/o atributos del catálogo	Catálogo del estudio	<b>Regla/segmentación:</b> priorización de evaluación/alertas y criterios de servicio
<b>Variabilidad de abastecimiento (incertidumbre de proveedores)</b>	<i>lead_time_dias</i> del catálogo + <b>buffer operativo</b> (p. ej., +2 días)	Catálogo del estudio + criterio operativo capturado en OE1	<b>Regla de alerta:</b> condición de oportunidad (horizonte $\geq$ lead time + buffer)

*Nota.* Elaboración propia. La matriz distingue entre variables que entrenan al modelo de IA (features) y parámetros que configuran la lógica de inventario, asegurando que el modelo responda a la realidad operativa documentada.

### 3.1.3 FASE 2: CUANTITATIVA - VALIDACIÓN EMPÍRICA (QUAN)

La fase cuantitativa valida el desempeño predictivo y la viabilidad técnica-operativa del modelo (OE2–OE4). Para ello se emplea una validación predictiva offline (backtesting) que simula condiciones reales de incertidumbre sin intervenir los procesos de reposición.

#### a) Validación temporal (Walk-Forward / Rolling Origin)

Se aplica validación de tipo Walk-Forward o Rolling Forecasting Origin (Hyndman & Athanasopoulos, 2021). Este enfoque respeta la causalidad temporal: el modelo se entrena con historia disponible hasta un tiempo  $t$  y predice el periodo futuro inmediato, desplazando la ventana de forma iterativa.

- **Train inicial:** 60 días
- **Paso (step):** 7 días

- **Horizontes:** 7, 14 y 28 días
- **Folds:** determinados por la combinación ventana/horizonte dentro de los 90 días

Este diseño evita **data leakage** y mide capacidad adaptativa del modelo en escenarios fuera de muestra.

### **b) Modelos de comparación (líneas base)**

Para asegurar comparabilidad, el modelo propuesto se contrasta contra líneas base reproducibles implementadas en el pipeline:

- **Baseline 1 (Naive):** persistencia del último valor disponible del entrenamiento.
- **Baseline 2 (Promedio móvil 30 días - SMA30):** promedio móvil como referencia simple.

Estas líneas base representan aproximaciones empíricas simples para evaluar si el modelo aporta mejora real.

### **c) Hipótesis inferencial (OE4)**

La prueba inferencial se plantea sobre diferencias pareadas por SKU ( $j$ ). Para cada SKU, se agrega por mediana el desempeño de sus folds del walk-forward para obtener una muestra independiente de  $n=120$  (un valor por SKU). Para cada SKU  $j$ , la diferencia se define frente a la línea base operativa (SMA30) en el horizonte de 14 días ( $h=14$ ), por ser el horizonte recomendado para operación y el utilizado en el contraste inferencial.

Para cada SKU  $j$ , se define:

$$D_j = MAE_{XGBoost,j} - MAE_{SMA30,j}$$

Hipótesis con significancia  $\alpha = 0.05$  (unilateral):

- $H_0: D_j \geq 0$  (No hay mejora)
- $H_1: D_j < 0$  (Existe mejora significativa)

Se aplica Wilcoxon signed-rank (no paramétrica) sobre la diferencia de errores. El rechazo de  $H_0$  a favor de  $H_1$  (si  $p < 0.05$ ) respalda que la mejora no es atribuible al azar y fortalece la viabilidad técnica.

**Nota metodológica (demanda=0):** Se distingue estrictamente entre demanda cero real (fenómeno observado, que se conserva) y vacíos de información por fechas faltantes. Las técnicas de imputación (forward-fill) se aplican exclusivamente a brechas de continuidad cronológica para no interrumpir los lags del algoritmo. En el análisis inferencial (sección 4.5), las comparaciones se realizan sobre MAE agregado por SKU, evitando sesgos por ceros en denominadores como ocurre con MAPE.

### 3.2 ALCANCE

Para subsanar posibles ambigüedades metodológicas y reflejar la naturaleza técnica del modelo desarrollado, el alcance de la investigación se define como Predictivo (No Experimental), manteniendo un carácter Propositivo en cuanto a su implementación operativa.

Según Hernández Sampieri y Mendoza (2018), los estudios de este tipo buscan cuantificar relaciones entre variables. En este caso, el alcance se materializa técnicamente al cuantificar la relación matemática no lineal entre las variables predictoras features como calendario operativo (día de semana, quincena) y dinámica reciente (lags, medias móviles) y la variable dependiente (demanda futura).

La clasificación se justifica en tres niveles de profundidad:

1. **Componente Predictivo (Núcleo del Estudio):** A diferencia de un estudio descriptivo que solo caracterizaría "cómo son" los quiebres de stock, esta investigación busca anticipar "cuándo ocurrirán". La utilización de algoritmos supervisados de la familia *Gradient Boosting* (OE2) y su validación mediante protocolos *Walk-Forward* (OE4) confiere al estudio un alcance inherentemente predictivo, ya que su éxito se mide por la capacidad de reducir la incertidumbre futura (minimización del error de pronóstico), no solo por narrar el pasado.
2. **Componente Correlacional (Mecanismo):** Para lograr la predicción, el modelo establece

correlaciones complejas entre patrones históricos y demanda futura. La fase de ingeniería de características demuestra cómo variables derivadas del calendario (p. ej., día de semana, mes, quincena, fin de semana) se asocian con variaciones de demanda, y el modelo utiliza esa estructura temporal para inferir comportamientos futuros.

3. **Carácter Propositivo (Límite Operativo):** Aunque la validación predictiva es rigurosa y estadística, el alcance operativo se mantiene como propositivo. Se diseña, especifica y valida técnicamente un modelo de información (Arquitectura y Algoritmos) para ser propuesto a la organización, sin llegar a la fase de despliegue en producción o ingeniería de software evolutiva, lo cual es coherente con las restricciones de tiempo y recursos del contexto académico.

### 3.3 DISEÑO DE LA INVESTIGACIÓN

Para garantizar la coherencia con el alcance predictivo y la validación temporal definida previamente, el diseño de la investigación se reconfigura técnicamente como No Experimental, Longitudinal Retrospectivo (de Tendencia) y de Estudio de Caso Único.

Esta clasificación corrige la limitación de un diseño puramente transversal, ya que la validación del modelo predictivo (OE4) requiere analizar la evolución del comportamiento de la demanda a lo largo de una ventana de tiempo histórica (90 días), y no simplemente describir el estado de la farmacia en un momento único.

1. No Experimental: Se observan y analizan los fenómenos (ventas, quiebres) tal y como ocurren en su contexto natural, sin manipular deliberadamente las variables de operación en la farmacia real durante el estudio.
2. Longitudinal Retrospectivo: Se recolectan y analizan datos históricos a través del tiempo (series temporales) para identificar tendencias, estacionalidad y patrones de cambio, lo cual es requisito sine qua non para el entrenamiento de algoritmos de Gradient Boosting.
3. Estudio de Caso Único: Se centra exclusivamente en la Sucursal San Pedro Sula de Farmacias Siman, permitiendo un análisis de profundidad técnica sobre la

interacción entre sus datos específicos y la arquitectura de nube propuesta (OE3).

### 3.3.1 DIAGRAMA DE TRAZABILIDAD DEL FLUJO DE INVESTIGACIÓN (ARQUITECTURA GCP)

Atendiendo a la exigencia de modelado propio, se presenta el Diagrama de Trazabilidad de Datos. Este esquema no es una ilustración genérica, sino el mapa exacto de cómo la investigación extrae, transforma y valida la evidencia empírica dentro del ecosistema de Google Cloud Platform, garantizando la trazabilidad desde el dato crudo hasta la métrica de error.

El flujo se estructura en cuatro etapas de ingeniería forense:

1. **Extracción (Fuente Primaria):** Captura de transacciones del POS local (CSV/Excel).
2. **Ingesta y Curaduría (BigQuery):** Normalización de datos y cálculo de variables (*Feature Engineering*).
3. **Modelado (Vertex AI):** Entrenamiento y validación *Walk-Forward* del algoritmo.
4. **Evidencia (Looker Studio):** Visualización de resultados y cálculo de KPI de éxito.



**Ilustración 12.** Diagrama Forense del Flujo de Datos y Procesamiento en GCP.

*Nota.* Elaboración propia. El diagrama modela la trazabilidad completa del dato, desde su origen transaccional en la sucursal hasta su transformación en evidencia estadística de validación.

## 3.4 POBLACIÓN

La población del estudio se delimita al caso único de la sucursal SPS e incluye: (i) N=120 SKUs; (ii) N=10,800 registros (90 días); (iii) n=3 actores clave; (iv) 4 subprocessos críticos.

Se trabaja con censo (n=N) dentro del alcance del caso.

### 3.4.1 COMPONENTE DE DATOS (NÚCLEO PREDICTIVO)

Para el entrenamiento y validación del modelo de *Gradient Boosting* (OE2 y OE4), la población objetivo se constituye por:

1. **Catálogo de Artículos (N<sub>1</sub> = 120 SKUs):** Selección estratégica de productos definida en el catálogo del estudio, priorizando los 105 medicamentos clasificados como esenciales (*es\_esencial=1*) según el campo del catálogo del estudio (alineado con criterios de la Lista Nacional de Medicamentos Esenciales) y 15 productos complementarios de alta rotación.
2. **Registros Transaccionales (N<sub>2</sub> = 10,800 Registros):** La totalidad de las transacciones históricas de venta, movimientos de inventario y recepciones generadas por los 120 SKUs seleccionados durante una ventana operativa de 90 días.

La selección de N=10,800 registros no es arbitraria; responde a la densidad de datos mínima necesaria para la convergencia de algoritmos de árboles de decisión (*Gradient Boosting*). Aunque la ventana temporal es corta (90 días), la alta frecuencia transaccional de los SKUs seleccionados garantiza suficiente varianza para que el modelo capture patrones de estacionalidad semanal (efecto fin de semana) y ciclicidad de liquidez (días de pago), permitiendo validar estadísticamente las hipótesis planteadas sin requerir series anuales completas.

### 3.4.2 COMPONENTE DE ACTORES (VALIDACIÓN CUALITATIVA)

Para la especificación de requisitos y validación de utilidad (OE1 y OE4), la población consta de los actores técnicos responsables de la toma de decisiones en la sucursal:

- **N<sub>3</sub> = 3 Actores Clave:** 1 Jefe de Farmacia y 2 Auxiliares Farmacéuticos.

Se seleccionan por ser los únicos usuarios con privilegios de administrador en el sistema actual y responsables directos del proceso de reposición. Su criterio experto es indispensable para parametrizar las reglas de negocio (tiempos de entrega, sustitutos) que el algoritmo no puede inferir solo de los datos.

### 3.4.3 COMPONENTE DE PROCESOS

- **N\_4 = 4 Subprocesos Críticos:** Planificación de demanda, Control de inventarios, Emisión de pedidos y Gestión de vencimientos. El estudio se limita estrictamente a estos flujos para garantizar la profundidad del análisis forense.

**Tabla 24.** *Resumen Técnico de la Población y Muestra Censal*

Unidad de Análisis	Población (N)	Muestra (n)	Criterio de Selección	Uso en el Modelo
<b>SKUs (Productos)</b>	120	120 (100%)	Campo es_esencial del catálogo (alineado LNME) + Pareto (alta rotación).	Definición del vector de características ( <i>Features</i> ).
<b>Transacciones</b>	10,800	10,800 (100%)	Ventana de 90 días completa (sin muestreo aleatorio).	Entrenamiento y Validación <i>Walk-Forward</i> .
<b>Actores Clave</b>	3	3 (100%)	Responsabilidad directa en la reposición.	Definición de Reglas de Negocio y Evaluación de Utilidad.

*Nota.* Elaboración propia. Al ser un estudio de ingeniería aplicada sobre un caso específico, se procesa la totalidad del universo disponible ( $n=N$ ) para maximizar la exactitud del modelo.

### 3.5 MUESTRA

En concordancia con el diseño de estudio de caso único y la naturaleza finita de la población identificada, esta investigación prescinde de técnicas de muestreo probabilístico o intencional. Se aplica un Censo Estricto ( $n=N$ ) sobre la totalidad del universo definido para el estudio (120 SKUs seleccionados). Al abarcar la totalidad de los elementos dentro de este alcance

delimitado, se elimina el error de muestreo dentro de la población del caso y se garantiza que los resultados reflejen el comportamiento del fenómeno estudiado en la sucursal, sin sesgos de selección; no obstante, esto no implica generalización automática a otras sucursales.

### 3.5.1 JUSTIFICACIÓN TÉCNICA DEL CENSO DE DATOS

Para el componente de datos (n=10,800 transacciones), la decisión de trabajar con la población completa obedece a una restricción crítica del modelado de series temporales: la continuidad cronológica. Cualquier técnica de muestreo aleatorio rompería la secuencia temporal de los datos, destruyendo los patrones de autocorrelación (dependencia entre el ayer y el hoy) que el algoritmo de *Gradient Boosting* necesita aprender. Para detectar la estacionalidad semanal (ej. picos de venta los viernes) y los ciclos de pago quincenales, es imperativo procesar el 100% de la historia operativa de los 90 días, sin omitir días ni transacciones.

### 3.5.2 JUSTIFICACIÓN OPERATIVA DEL CENSO DE ACTORES

Para el componente humano (n=3), se incluye a la totalidad de la fuerza técnica de la sucursal (1 Jefe y 2 Auxiliares). Al ser un equipo reducido, la exclusión de un solo participante implicaría perder el 33% de la visión operativa o el 100% de la visión estratégica (en el caso del Jefe), lo cual comprometería la validez de los requisitos levantados en el Objetivo Específico 1.

**Tabla 25.** *Matriz de Correspondencia Población-Muestra (Censo)*

<b>Componente</b>	<b>Población (N)</b>	<b>Muestra (n)</b>	<b>Técnica</b>	<b>Justificación del Censo</b>
<b>Datos Transaccionales</b>	10,800	<b>10,800</b>	Censo Automático	Preservación de patrones secuenciales para <i>Machine Learning</i> .
<b>Catálogo de Productos</b>	120	<b>120</b>	Censo	Cobertura total de la curva ABC de ingresos y criticidad.
<b>Actores Clave</b>	3	<b>3</b>	Censo	Captura integral de la visión estratégica y operativa.

*Nota.* Elaboración propia. Al aplicar  $n=N$ , la inferencia estadística se realiza sobre el comportamiento real del sistema, no sobre estimaciones probabilísticas.

### 3.6 TÉCNICA DE MUESTREO

En coherencia con el diseño de caso único y la naturaleza finita de la población, se selecciona como única metodología la Técnica de Muestreo Censal (Enumeración Total). Se descarta explícitamente el uso de técnicas probabilísticas o aleatorias, ya que la fragmentación de la muestra introduciría un error sistemático inaceptable para los objetivos del modelado predictivo.

La decisión metodológica se fundamenta en dos imperativos técnicos:

1. **Integridad de la Serie Temporal (Componente Cuantitativo):** El entrenamiento de algoritmos de *Gradient Boosting* requiere preservar la estructura secuencial de los datos. La aplicación de cualquier técnica de muestreo aleatorio rompería la continuidad cronológica, eliminando la autocorrelación necesaria para detectar patrones como la estacionalidad semanal o los ciclos de pago. Por tanto, la única técnica viable es la ingestión del 100% de los registros transaccionales ordenados temporalmente.
2. **Saturación Operativa (Componente Cualitativo):** Dado que el universo de actores técnicos es extremadamente reducido ( $N=3$ ), la aplicación de muestreo selectivo generaría un sesgo de exclusión. La técnica censal garantiza que la especificación de requisitos (OE1) integre la totalidad de las visiones disponibles (estratégica y operativa), eliminando el riesgo de omitir reglas de negocio críticas que solo conoce un actor específico.

En síntesis, no se selecciona una porción representativa; se procesa la totalidad del sistema para garantizar que el modelo matemático aprenda del comportamiento real y no de una aproximación estadística.

### 3.7 CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN

Para garantizar la calidad del insumo que alimenta el modelo de *Gradient Boosting* y la validez de los requisitos operativos, se aplican filtros técnicos estrictos sobre la población censal. Estos criterios aseguran que el modelo no aprenda de "ruido" (datos corruptos) y que la validación operativa recaiga en actores con verdadera injerencia en el proceso.

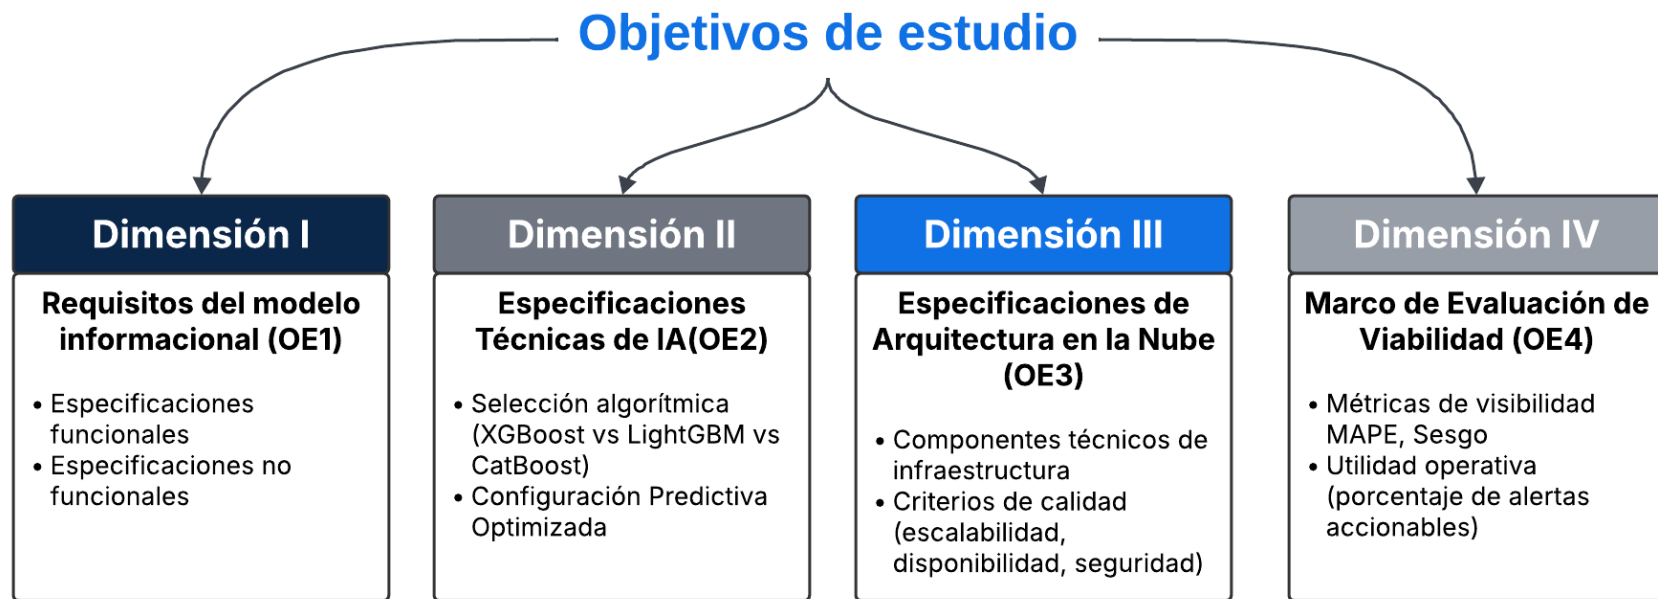
**Tabla 26. Criterios de Inclusión y Exclusión por Ámbito de Estudio**

Ámbito de Estudio	Criterios de Inclusión (Filtro de Entrada)	Criterios de Exclusión (Filtro de Salida)
<b>Datos Operativos (Dataset)</b>	<p><b>Calidad de Dato:</b> Registros transaccionales de los 120 SKUs seleccionados que presenten un indicador de completitud y consistencia &gt; 95% (calculado como porcentaje de registros con campos clave válidos y referencialmente íntegros).</p> <p><b>Ventana Temporal:</b> Transacciones ocurridas estrictamente dentro de la ventana de 90 días de observación (Serie continua).</p>	<p><b>Datos Corruptos:</b> Registros huérfanos (sin integridad referencial) o series temporales con <i>gaps</i> (vacíos de información) superiores al 5% que impidan la imputación confiable.</p> <p><b>Outliers Técnicos:</b> Transacciones de prueba, devoluciones administrativas o ajustes contables que no reflejan demanda real.</p>
<b>Procesos Operativos</b>	<p><b>Generadores de Datos:</b> Subprocesos que dejan huella digital en el sistema POS: Venta en mostrador, Recepción de pedidos y Ajuste de inventario.</p> <p><b>Criticidad:</b> Procesos vinculados directamente a la reposición de los 105 medicamentos esenciales.</p>	<p><b>Procesos Manuales no Trazables:</b> Consultas verbales, pedidos vía telefónica no registrados en sistema o tareas administrativas sin impacto en el stock lógico.</p>
<b>Actores Técnicos</b>	<p><b>Rol Activo:</b> Personal de la sucursal San Pedro Sula con credenciales de acceso al sistema POS y autoridad para ejecutar o solicitar pedidos de reposición (Jefe y Auxiliares).</p>	<p><b>Rol Pasivo:</b> Personal de caja, limpieza o seguridad sin privilegios de sistema para la gestión de inventarios, o personal corporativo externo a la operación diaria de la sucursal.</p>

*Nota.* Elaboración propia. El umbral de fidelidad del 95% se establece como estándar de calidad de datos mínimo para garantizar la convergencia de los algoritmos de Machine Learning.

### 3.8 ESQUEMA DE VARIABLES

El esquema de variables se alinea con el alcance predictivo y el diseño no experimental del estudio. A diferencia de un enfoque puramente descriptivo, este modelo operacionaliza la relación funcional entre los datos históricos (Variables Predictoras) y el desempeño del pronóstico (Variables de Respuesta). Esta estructura permite evaluar cuantitativamente el cumplimiento de la hipótesis planteada ( $H_1$ ), vinculando los insumos técnicos con los resultados de negocio esperados.



**Ilustración 13.** *Esquema de Dimensiones de Análisis del Modelo Conceptual Según Objetivos Específicos*

*Nota.* El esquema presenta las cuatro dimensiones de análisis correspondientes a los objetivos específicos (OE1-OE4) del estudio.

### 3.9 OPERACIONALIZACIÓN DE VARIABLES

Esta sección traduce los conceptos teóricos en métricas de ingeniería verificables, estableciendo umbrales de aceptación numéricos (KPIs) para determinar el éxito del modelo predictivo y su arquitectura subyacente.

#### 3.9.1 REQUISITOS DEL MODELO INFORMACIONAL

**Definición Operativa:** Especificación técnica de las funciones críticas que el sistema debe ejecutar para mitigar el riesgo de desabastecimiento, validadas contra las expectativas del personal farmacéutico y las restricciones de datos disponibles (90 días históricos).

**Tabla 27.** Operacionalización de Variables - Objetivo 1

Variable	Dimensión	Indicador de medición	Umbral de aceptación (meta)
<b>Requisitos funcionales</b>	Utilidad percibida	Mediana en escala Likert (1–5) de ítems D1–D5	Mediana $\geq 4$
<b>Cobertura de reglas</b>	Cobertura de heurísticas	Hallazgos cualitativos validados / Total H1–H4	4/4 = 100% de hallazgos cualitativos incorporados en requisitos
<b>Requisitos no funcionales</b>	Disponibilidad y calidad de datos	Índice de fidelidad e integridad del dataset	> 95% de registros válidos
<b>Capacidad tecnológica</b>	Factibilidad de infraestructura	Cumplimiento de checklist de conectividad y codificación (Ítems críticos)	100% de ítems habilitadores (Internet/SKU único)

*Nota.* Elaboración propia. El umbral de capacidad tecnológica se enfoca en los habilitadores de infraestructura crítica (Red y Datos) necesarios para el despliegue en la nube, diferenciándolos de las capacidades operativas manuales.

#### 3.9.2 ESPECIFICACIONES TÉCNICAS DE IA

**Definición Operativa:** Selección y configuración del algoritmo de Gradient Boosting

(XGBoost) optimizado para series temporales cortas, evaluado mediante un protocolo de validación cruzada temporal (Walk-Forward) para asegurar evaluación fuera de muestra y robustez operativa.

**Tabla 28.** Operacionalización de Variables - Objetivo 2

Variable	Dimensión	Indicador de medición	Umbral de aceptación (meta)
<b>Desempeño predictivo</b>	Precisión porcentual	MAPE (Mean Absolute Percentage Error)	MAPE < 25% (umbral mínimo aceptable)  (Meta aspiracional: <10%)
	Exactitud absoluta	MAE (vs baselines: Naive y Promedio móvil 30 días – SMA30)	MAE_propuesto ≤ 0.70 × MAE_baseline (≥30% mejora)
	Sesgo (tendencia)	Ratio  Bias  / MAE ( <i>Bias = Error Medio</i> )	≤ 0.60
<b>Eficiencia computacional</b>	Costo de entrenamiento	Tiempo de ejecución por fold (walk-forward)	< 60 s/fold (viabilidad operativa en Cloud Run)
<b>Selección algorítmica</b>	Evaluación multicriterio	Puntaje ponderado: Precisión predictiva (40%), Eficiencia computacional (20%), Interpretabilidad (20%), Robustez (20%) = 100 puntos máximo	Algoritmo ganador = mayor score

*Nota.* Elaboración propia. MAE/MAPE y Bias (Mean Error) son métricas estándar de evaluación de pronósticos; el contraste con baseline y el cálculo por walk-forward aseguran comparabilidad temporal.

### 3.9.3 ARQUITECTURA EN LA NUBE

**Definición Operativa:** Diseño de la infraestructura en Google Cloud Platform (GCP) bajo principios SRE (Site Reliability Engineering), midiendo la confiabilidad a través de Objetivos de Nivel de Servicio (SLO) explícitos.

**Tabla 29. Operacionalización de Variables - Objetivo 3**

<b>Variable</b>	<b>Dimensión</b>	<b>Indicador de medición</b>	<b>Umbral de aceptación (SLO/Meta)</b>
<b>Confiabilidad (SRE)</b>	Disponibilidad del servicio	Uptime mensual diseñado (Service Level Objective)	<b>SLO ≥ 99.0%</b> <i>(Error budget ~7.2 h/mes)</i>
<b>Rendimiento</b>	Latencia de experiencia (UX)	Latencia p95 del dashboard (tiempo de carga)	<b>&lt; 3 segundos</b>
<b>Seguridad</b>	Protección de datos	Cobertura de cifrado (Tránsito y Reposo)	<b>100% de datos cifrados</b> <i>(AES-256 / TLS 1.3)</i>
<b>Escalabilidad</b>	Elasticidad Serverless	Configuración de instancias (Cloud Run)	<b>Escalado a cero (0)</b> <i>(min=0, max=10; cumple max≥2)</i>
<b>Calidad Arquitectónica</b>	Cumplimiento de Estándares	Score Global del Well-Architected Framework	<b>≥ 70% (Aceptable)</b>

*Nota.* Elaboración propia. Los SLO se declaran como criterios de diseño arquitectónico; su medición operativa corresponde a una fase de implementación productiva fuera del alcance del presente estudio. Umbrales alineados con Google Cloud Well-Architected Framework.

### 3.9.4 MARCO DE EVALUACIÓN DE VIABILIDAD

**Definición Operativa:** Sistema de validación integral que combina la precisión técnica con la utilidad del negocio, midiendo no solo el error matemático, sino la capacidad del modelo para generar Alertas Accionables que prevengan quiebres de stock reales.

**Tabla 30. Operacionalización de Variables - Objetivo 4**

<b>Variable</b>	<b>Dimensión</b>	<b>Indicador de medición</b>	<b>Umbral de aceptación (meta)</b>
-----------------	------------------	------------------------------	------------------------------------

<b>Viabilidad técnica</b>	Significancia	Wilcoxon signed-rank sobre diferencias de error	Se reporta p-value de Wilcoxon como evidencia complementaria (no excluyente) dada la naturaleza del estudio; se interpreta junto a MAPE/MAE y utilidad operativa
<b>Utilidad operativa</b>	Alertas accionables	% de alertas accionables	<b>≥ 70% (umbral mínimo viable); meta aspiracional ≥ 75%</b>
<b>Oportunidad</b>	Lead time	% de alertas cuyo horizonte de predicción cumple (≥ lead time + buffer definido) según regla operativa del estudio	<b>≥ 85%</b>
<b>Resultado global</b>	Score de viabilidad	Índice ponderado	<b>≥ 85/100</b> (“Altamente viable”)

*Nota.* Elaboración propia. La métrica de "% Alertas Accionables" valida que el sistema entregue valor real al negocio más allá de la precisión académica. El umbral de Lead Time se ajusta al 85% reconociendo la variabilidad extrema de proveedores locales.

### 3.10 TÉCNICAS, INSTRUMENTOS, PROCEDIMIENTOS Y PLAN DE ANÁLISIS

#### 3.10.1 IDENTIFICAR REQUISITOS

**Tabla 31.** *Metodología para Identificación de Requisitos del Modelo Informacional*

<b>Aspecto</b>	<b>Especificación</b>
<b>Técnica</b>	Encuesta estructurada y validación técnica del instrumento ETL (ejecución controlada de script SQL en BigQuery).
<b>Justificación</b>	La encuesta estandariza la percepción de utilidad de los usuarios, mientras que la revisión del código SQL valida la factibilidad técnica de la extracción de datos desde el POS y la Matriz de Disponibilidad certifica la calidad de las fuentes.
<b>Instrumentos</b>	• <b>Cuestionario Estructurado:</b> Escalas Likert D1-D5 y preguntas abiertas (Google Forms) ( <a href="#">ver Anexo I</a> ).

	<ul style="list-style-type: none"> <li>• <b>Matriz de Requisitos:</b> Priorización MoSCoW de RF/RNF (<a href="#">ver Anexo II</a>).</li> <li>• <b>Matriz de Disponibilidad/Calidad de Datos:</b> Evaluación de 6 dimensiones de calidad en fuentes FD-001 a FD-004 (<a href="#">ver Anexo III</a>)</li> <li>• <b>Instrumento Técnico ETL:</b> Script de validación de extracción de datos (SQL BigQuery) para confirmar disponibilidad de campos (<a href="#">ver Anexo XIII</a>).</li> </ul>
<b>Procedimiento</b>	<ol style="list-style-type: none"> <li>1. <b>Levantamiento:</b> Aplicación del cuestionario a la totalidad de actores (n=3): Jefe de Farmacia y Auxiliares.</li> <li>2. <b>Evaluación de Fuentes:</b> Auditoría de calidad de datos (completitud, consistencia) llenando la Matriz de Disponibilidad.</li> <li>3. <b>Validación Técnica:</b> Ejecución del script ETL piloto sobre una muestra de 100 transacciones para verificar la integridad referencial de fecha, sku y cantidad.</li> <li>4. <b>Triangulación:</b> Cruce de la "necesidad percibida" (Encuesta Sección H) con la "capacidad técnica" (Matriz Disponibilidad).</li> </ol>
<b>Plan de Análisis</b>	<ul style="list-style-type: none"> <li>• <b>Cuantitativo (Encuesta):</b> Cálculo de moda y mediana para ítems Likert (D1-D5); conteo de brechas de infraestructura (Checklist F1-F4).</li> <li>• <b>Cualitativo (Heurísticas):</b> Análisis temático de preguntas abiertas (H1-H4) para identificar reglas de negocio.</li> <li>• <b>Calidad de Datos:</b> Evaluación de las 6 dimensiones (completitud, exactitud, etc.) de la Matriz de Disponibilidad para dictaminar si las fuentes son "Viabes", "Parciales" o "No Viabes".</li> <li>• <b>Técnico (ETL):</b> Verificación binaria (Pasa/Falla) definida como control de calidad previo a la ingesta. La evidencia del control se documenta mediante el script SQL del Anexo XIII y su ejecución controlada sobre una muestra (LIMIT 100), registrando el resultado en el log de validación.</li> </ul>

Nota. Elaboración propia.

### 3.10.2 DEFINIR TÉCNICAS DE IA

**Tabla 32.** Metodología para Selección de Técnicas de Inteligencia Artificial

Aspecto	Especificación
<b>Técnica</b>	Benchmarking algorítmico multicriterio con validación cruzada temporal (Walk-Forward Validation).
<b>Justificación</b>	Permite evidenciar diferencias empíricas de desempeño entre XGBoost, LightGBM y CatBoost en series temporales cortas (90 días), evitando el sobreajuste mediante evaluación fuera de muestra y asegurando métricas comparables en horizontes de predicción definidos.
<b>Instrumentos</b>	<ul style="list-style-type: none"> <li>• <b>Matriz de Evaluación Comparativa:</b> Scorecard multicriterio (4 criterios × 3 algoritmos) con scoring ponderado 40/20/20/20% (<a href="#">ver Anexo IV</a>).</li> <li>• <b>Scripts de Python:</b> Documentados en (<a href="#">ver Anexo VI: PROTOCOLO DE VALIDACIÓN WALK-FORWARD.py</a>; <a href="#">ver Anexo V: SCRIPTS BACKTESTING AUTOMATIZADO.py</a>).</li> <li>• <b>Verificación de Interpretabilidad:</b> Comprobación de soporte nativo SHAP (pred_contribs, get_feature_importance) mediante documentación técnica oficial (criterio de diseño: 20%).</li> <li>• <b>Verificación de Robustez:</b> Confirmación de manejo nativo de NaN (valores nulos) en las tres librerías mediante documentación técnica oficial (criterio de diseño: 20%).</li> </ul>
<b>Procedimiento</b>	<ol style="list-style-type: none"> <li>1. <b>Preparación de Datos:</b> 120 SKUs de medicamentos esenciales (ATC) con feature engineering temporal alineado al protocolo: lags (7, 14, 28 días), medias móviles (7, 14, 30 días) y variables de calendario (day_of_week, month, is_weekend).</li> <li>2. <b>Entrenamiento:</b> Ejecución paralela de XGBoost, LightGBM y CatBoost.</li> <li>3. <b>Validación Walk-Forward:</b> Ventana inicial de 60 días, incremento de 7 días por fold, evaluando horizontes de 7, 14 y 28 días mediante backtesting fuera de muestra. Folds variables según horizonte (4 folds para 7 días, etc.).</li> <li>4. <b>Selección:</b> Comparación multicriterio y selección final del algoritmo ganador.</li> </ol>
<b>Plan de Análisis</b>	1. <b>Preparación de Datos:</b> 120 SKUs con <i>feature engineering</i> temporal alineado al protocolo validado: lags (7, 14, 28 días), medias móviles (7, 14, 30 días) y variables categóricas de calendario (day_of_week, month, is_weekend). Demanda=0 se conserva como valor válido.

	<p>Para evitar distorsión en MAPE, se usa denominador estabilizado cuando <math>y=0</math> (según el protocolo) y la imputación aplica solo a días faltantes/no registrados (p. ej., forward-fill), documentándolo.</p> <p>2. <b>Entrenamiento:</b> Ejecución paralela de XGBoost, LightGBM y CatBoost.</p> <p>3. <b>Validación Walk-Forward:</b> Ventana inicial 60 días, incremento 7 días, horizontes 7/14/28 días.</p> <p>4. <b>Selección:</b> Comparación multicriterio.</p>
--	---

*Nota.* Elaboración propia basada en Hyndman & Athanasopoulos (2021) para el protocolo de validación walk-forward y Lundberg & Lee (2017) para interpretabilidad.

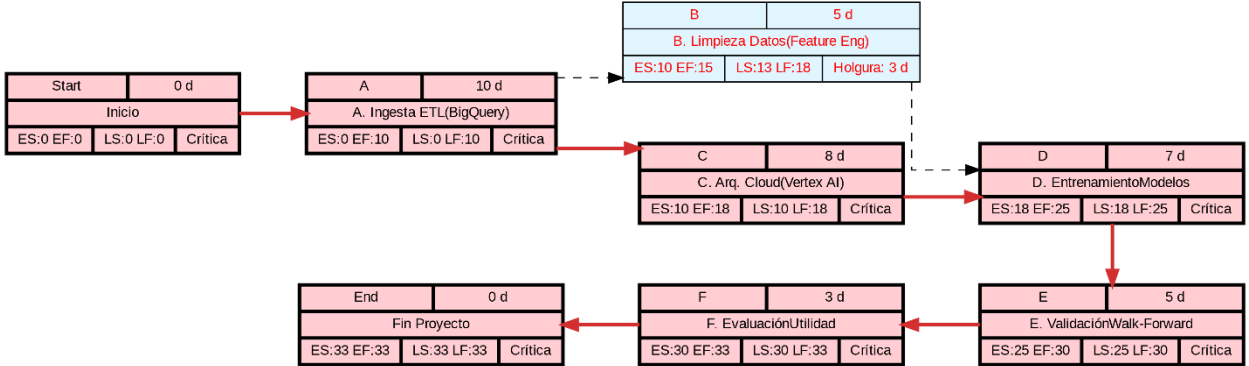
### 3.10.3 ESPECIFICAR ARQUITECTURA

**Tabla 33.** *Metodología para Especificación Arquitectónica*

Aspecto	Especificación
<b>Técnica</b>	Diseño iterativo TOGAF ADM con validación de Ruta Crítica (PERT).
<b>Justificación</b>	TOGAF ADM provee un marco estructurado para alinear requisitos de negocio con la tecnología de forma trazable, mientras que el análisis PERT asegura la viabilidad temporal del despliegue. El GCP Well-Architected Framework aporta criterios de validación de calidad.
<b>Instrumentos</b>	<ul style="list-style-type: none"> <li>• <b>Plantillas TOGAF ADM:</b> Documentación de Fases A–F (<a href="#">ver Anexo VII</a>).</li> <li>• <b>Matriz de Trazabilidad:</b> Cruce de Requisitos vs. Componentes (<a href="#">ver Anexo XII</a>).</li> <li>• <b>Checklist Well-Architected GCP:</b> Validación de rendimiento, seguridad y operación (<a href="#">ver Anexo VIII</a>).</li> <li>• <b>Guía SRE:</b> Definición de SLO/SLI y error budget (<a href="#">ver Anexo VIII</a>).</li> </ul>
<b>Procedimiento</b>	<ul style="list-style-type: none"> <li>• <b>Fase A (Visión):</b> Definición de principios, stakeholders y restricciones académicas.</li> <li>• <b>Fase B (Negocio):</b> Mapeo de procesos farmacéuticos y capacidades objetivo.</li> </ul>

	<ul style="list-style-type: none"> <li>• <b>Fase C (Sistemas):</b> Arquitectura de Datos (BigQuery, Pub/Sub) y Aplicaciones (Vertex AI, Looker Studio).</li> <li>• <b>Fase D (Tecnología):</b> Infraestructura GCP, seguridad (IAM, KMS) y redes.</li> <li>• <b>Fase E/F (Solución/Migración):</b> Identificación de gaps y cronograma de implementación.</li> <li>• <b>Análisis de Ruta Crítica:</b> Modelado de dependencias (ETL -&gt; Configuración -&gt; Modelo) para identificar cuellos de botella (ver Ilustración 14).</li> </ul>
<b>Plan de Análisis</b>	<ul style="list-style-type: none"> <li>• <b>Validación Estructural:</b> Verificación de cobertura 100% en la Matriz de Trazabilidad (Requisito - Componente).</li> <li>• <b>Validación Operativa:</b> Revisión sistemática de pilares Well-Architected (Seguridad, Eficiencia de Desempeño y Excelencia Operativa).</li> <li>• <b>Validación Temporal (PERT):</b> El análisis de la ruta crítica metodológica establece una duración mínima de 33 días para la fase de validación del modelo. La secuencia crítica es: A (Ingesta/ETL) -&gt; D (Entrenamiento) -&gt; E (Validación Walk-Forward) -&gt; F (Evaluación). La actividad de Limpieza de Datos Históricas (5 días) se ejecuta en paralelo a la construcción del Pipeline ETL (10 días), contando con una holgura de 5 días, lo que otorga flexibilidad operativa sin retrasar el hito de validación final.</li> </ul>

Nota. Elaboración propia basada en TOGAF® Standard, 10th Edition y Google Cloud Architecture Framework.



**Ilustración 14. Red PERT del Proceso Metodológico (OE1-OE4)**

Nota. Elaboración propia. La ruta crítica (A→C→D→E→F = 33 días) se indica en nodos sombreados (rosa). La actividad B (Limpieza de Datos) tiene holgura de 3 días, permitiendo flexibilidad en su ejecución sin afectar la duración total del proyecto.

### 3.10.4 MARCO DE EVALUACIÓN

**Tabla 34.** Metodología para Marco de Evaluación de Viabilidad

Aspecto	Especificación
<b>Técnica</b>	Backtesting forense y Simulación de utilidad operativa.
<b>Justificación</b>	Busca un balance entre precisión estadística (medida fuera de muestra) y utilidad práctica para decisiones farmacéuticas. El backtesting walk-forward simula condiciones reales de uso para evaluar la robustez.
<b>Instrumentos</b>	<ul style="list-style-type: none"> <li>• <b>Scripts de Evaluación:</b> SCRIPTS BACKTESTING AUTOMATIZADO.py (<a href="#">ver anexo V</a>) y SCRIPT PYTHON UTILIDAD DE ALERTAS.py (<a href="#">ver Anexo XI</a>).</li> <li>• <b>Marco de Evaluación de Viabilidad:</b> Framework integral con scoring ponderado (<a href="#">ver Anexo IX - MARCO DE EVALUACIÓN DE VIABILIDAD.pdf</a>).</li> <li>• <b>Matriz de Utilidad Operativa:</b> Definición de alerta accionable, lead time, umbrales (<a href="#">ver Anexo X- MATRIZ DE UTILIDAD OPERATIVA.pdf</a>).</li> </ul>
<b>Procedimiento</b>	<ol style="list-style-type: none"> <li>1. <b>Definición de Métricas:</b> Establecimiento de umbrales (MAPE &lt; 35%, Alertas Accionables <math>\geq 70\%</math>).</li> <li>2. <b>Backtesting Temporal:</b> Validación cruzada con horizontes de 7, 14 y 28 días.</li> <li>3. <b>Evaluación de Utilidad:</b> Clasificación de alertas como "Accionables" si cumplen criterios de anticipación (Lead Time) y confianza.</li> <li>4. <b>Síntesis:</b> Cálculo del Score de Viabilidad conforme al marco ponderado: Viabilidad Técnica (60%) + Utilidad Operativa (25%) + Aceptación Usuario (15%).</li> </ol>
<b>Plan de Análisis</b>	<ul style="list-style-type: none"> <li>• <b>Simulación:</b> Ejecución de scripts en Python para cálculo automático de métricas.</li> <li>• <b>Estadística:</b> Estimación de intervalos de confianza y análisis de robustez mediante bootstrap (10,000 remuestreos) sobre la unidad de análisis (SKUs).</li> <li>• <b>Criterios de Decisión:</b> El modelo es viable si: <ul style="list-style-type: none"> <li>(i) Cumple umbrales de precisión (MAPE &lt; 35%).</li> </ul> </li> </ul>

	<p>(ii) Supera el umbral operativo de <math>\geq 70\%</math> de <b>Alertas Accionables</b> (validado en resultados reales).</p> <p>(iii) Obtiene un scoring integral <math>\geq 85/100</math> puntos (Altamente Viable).</p> <p>(iv) El scoring integral se calcula como: Viabilidad Técnica (60%) + Utilidad Operativa (25%) + Aceptación Usuario (15%).</p>
--	---

*Nota.* Elaboración propia basada en Hyndman & Athanasopoulos (2021) para métricas predictivas y Tavakol & Dennick (2011) para validación de escalas.

### 3.11 FUENTES DE INFORMACIÓN

La estrategia de fuentes de información se define bajo un principio de viabilidad técnica y trazabilidad, priorizando fuentes (i) bajo control operativo directo, (ii) con estructura digital y (iii) con llaves mínimas (fecha, SKU, cantidad) que permitan preservar integridad referencial y reproducibilidad del pipeline de ingesta y análisis. Esta priorización es consistente con marcos de calidad de datos que distinguen entre calidad inherente y dependiente del sistema, y recomiendan asegurar características verificables para el uso analítico (p. ej., consistencia, exactitud, completitud, validez).

#### 3.11.1 FUENTES PRIMARIAS

Las fuentes primarias constituyen el núcleo informacional del estudio y se limitan al perímetro interno de Farmacias Siman para garantizar que el conjunto de entrenamiento y evaluación mantenga consistencia temporal y calidad verificable. En modelos predictivos evaluados con esquemas walk-forward/rolling origin, el entrenamiento debe usar únicamente observaciones anteriores al periodo de prueba; por tanto, la prioridad es disponer de series internas completas y coherentes, no de amplitud de fuentes heterogéneas difíciles de integrar.

**Tabla 35. Fuentes Primarias del Estudio**

<b>Tipo de fuente</b>	<b>Descripción</b>	<b>Justificación técnica</b>	<b>Criterios de calidad</b>
<b>Datos organizacionales (internos)</b>	Registros transaccionales POS e inventario de la sucursal (120 SKUs; 10,800 registros; ventana de 90 días) + catálogo interno del estudio	Fuente estructurada y trazable (CSV/SQL-ready) con llaves mínimas (fecha-SKU-cantidad) apta para ingesta y validación temporal sin intervención manual	Compleitud y validez en campos clave $\geq 95\%$ ; granularidad diaria por SKU; consistencia de llaves (fecha/SKU)
<b>Personal operativo</b>	Jefe de farmacia (n=1) y auxiliares (n=2)	Fuente necesaria para parametrizar reglas/heurísticas (p. ej., criterios de reposición, interpretación de quiebres) que no se observan explícitamente en el POS	Rol activo en reposición; participación directa en operaciones de la sucursal
<b>Infraestructura tecnológica</b>	Sistema POS y conectividad local de la sucursal	Evidencia técnica para validar factibilidad de operación (captura de datos, estabilidad de acceso) y restricciones de implementación	Acceso operativo a registros/logs; verificación en diagnóstico OE1

*Nota.* Elaboración propia. Los criterios de calidad se alinean con el enfoque de calidad de datos (calidad inherente y dependiente del sistema) para garantizar uso analítico reproducible.

### 3.11.2 FUENTES SECUNDARIAS

Las fuentes secundarias respaldan el marco técnico y metodológico del estudio:

**Tabla 36. Fuentes Secundarias del Estudio**

<b>Categoría</b>	<b>Descripción</b>	<b>Justificación</b>	<b>Criterios de selección</b>
------------------	--------------------	----------------------	-------------------------------

<b>Literatura científica</b>	Evidencia sobre forecasting y modelos tipo gradient boosting en contextos de datos limitados	Sustentar decisiones de modelado y evaluación	Publicaciones arbitradas e indexadas
<b>Documentación técnica</b>	Documentación oficial de arquitectura cloud y marcos de arquitectura	Asegurar que la arquitectura propuesta sea desplegable y verificable	Fuentes oficiales del proveedor / estándares reconocidos

*Nota.* Elaboración propia.

### 3.11.3 DELIMITACIÓN Y EXCLUSIÓN DE FUENTES (PROVEEDORES EXTERNOS)

Durante el levantamiento del OE1 (Encuesta + Matriz de Disponibilidad y Calidad), se consideró la incorporación de fuentes externas de proveedores (droguerías/distribuidores) —por ejemplo: confirmaciones de entrega, disponibilidad en proveedor y tiempos de despacho—; sin embargo, no se incorporaron al dataset del estudio por razones técnicas y de gobernanza coherentes con el alcance aprobado:

1. Estructura e interoperabilidad insuficiente para ingesta automatizada: para integrar datos inter-organizacionales sin intervención manual se requiere un mecanismo de intercambio estructurado (p. ej., EDI o equivalente), que habilite transmisión computador-a-computador y reduzca errores humanos. En ausencia de este tipo de intercambio, la ingesta se vuelve manual y eleva el riesgo de inconsistencia.
2. Riesgo de degradación de calidad y trazabilidad: el estudio exige llaves mínimas (fecha-SKU-cantidad) y consistencia temporal para entrenamiento/validación. La incorporación de fuentes externas no estandarizadas habría requerido instrumentación adicional (normalización, homologación de catálogos, controles de calidad extendidos) que excede el alcance definido (instrumentos ya aplicados).
3. Alineación con el foco del modelo: el objetivo del componente predictivo es estimar demanda interna (comportamiento de consumo observado en el POS). La incertidumbre de suministro se incorpora como restricción/parametrización interna

(p. ej., lead time estimado por personal experto y parámetros del catálogo), en lugar de requerir conectividad en tiempo real con proveedores externos.

En síntesis, la fuente de proveedores externos no se ignoró: se evaluó durante el levantamiento del OE1 y se excluyó por inviabilidad técnica dentro del alcance aprobado.

Implicación metodológica: esta delimitación fortalece la validez interna y la reproducibilidad del pipeline, pero limita la extensión del modelo hacia analítica de desempeño de proveedores (línea futura).

### 3.12 MATRIZ METODOLÓGICA

Pregunta de Investigación	Objetivo Específico	Metodología	Variable	Dimensión	Indicadores	Instrumentos
¿Cuáles son los requisitos funcionales y no funcionales necesarios para desarrollar un modelo de información con capacidades predictivas de plataforma digital adaptado	Identificar los requisitos funcionales y no funcionales del modelo de información con capacidades predictivas, considerando las condiciones tecnológicas y operativas de	<b>Mixta</b> (Cualitativa dominante)	Requisitos funcionales	Utilidad percibida	Mediana en escala Likert (1–5) de ítems D1–D5	• Cuestionario estructurado con escalas Likert y preguntas abiertas (Google Forms) ( <a href="#">ver Anexo I</a> )
			Cobertura de reglas	Cobertura de heurísticas	Hallazgos cualitativos validados / Total H1–H4	• Cuestionario estructurado con escalas Likert y preguntas abiertas (Google Forms) ( <a href="#">ver Anexo I</a> )

<b>a las condiciones tecnológicas y operativas de Farmacias Siman?</b>	Farmacias Siman, así como las limitaciones de procesos y datos disponibles.		Requisitos no funcionales	Disponibilidad y calidad de datos	Índice de fidelidad e integridad del dataset	<ul style="list-style-type: none"> <li>• Matriz de disponibilidad/calidad de datos (<a href="#">ver Anexo III</a>)</li> <li>• Script ETL/SQL de validación (BigQuery) (<a href="#">Anexo XIII</a>)</li> </ul>
			Capacidad tecnológica	Factibilidad de infraestructura	Cumplimiento de checklist de conectividad y codificación (Ítems críticos)	<ul style="list-style-type: none"> <li>• Cuestionario estructurado con escalas Likert y preguntas abiertas (Google Forms) (<a href="#">ver Anexo I</a>)</li> </ul>
<b>¿Qué enfoque de inteligencia artificial y técnicas de análisis de datos</b>	Definir el enfoque de inteligencia artificial y las técnicas de análisis de datos para	Cuantitativa/Cualitativa	Desempeño Predictivo	Precisión porcentual	MAPE (Mean Absolute Percentage Error)	<ul style="list-style-type: none"> <li>• <a href="#">Anexo V</a> (SCRIPTS BACKTESTING AUTOMATIZADO.py)</li> <li>• <a href="#">Anexo VI</a> (PROTOCOLO DE</li> </ul>

<b>deben seleccionarse para apoyar la reposición de medicamentos esenciales en el contexto específico de Farmacias Siman y por qué razones técnicas?</b>	apoyar la reposición de medicamentos esenciales en Farmacias Siman, enfocado en información accionable para mitigar quiebres y priorizar reposiciones.					VALIDACIÓN WALK-FORWARD.py)		
						Exactitud absoluta	MAE (vs baseline Naive estacional)	• <a href="#">Anexo V</a> (SCRIPTS BACKTESTING AUTOMATIZADO.py)
						Sesgo (tendencia)	Ratio $ Bias  / MAE$ ( <i>Bias = Error Medio</i> )	• <a href="#">Anexo V</a> (SCRIPTS BACKTESTING AUTOMATIZADO.py)
						Eficiencia computacional	Costo de entrenamiento	Tiempo de ejecución por fold (walk-forward)
			Selección algorítmica	Evaluación multicriterio	Puntaje ponderado (precisión/eficiencia/interpretabilidad/robustez)	• <a href="#">Anexo IV</a> (MATRIZ DE EVALUACIÓN DE ALGORITMOS ML)		
<b>¿Cómo debe diseñarse la infraestructura en la nube que soporte el procesamiento,</b>	Especificar la arquitectura en la nube que sustente la ingesta, el procesamiento, el almacenamiento y	Cualitativa	Confiabilidad (SRE)	Disponibilidad del servicio	Uptime mensual diseñado (Service Level Objective)	• Plantillas TOGAF ADM (fases A–F) ( <a href="#">ver Anexo VII</a> )  • Checklist Well-Architected GCP (rendimiento, seguridad,		

<b>almacenamiento y visualización de datos, garantizando escalabilidad, disponibilidad y seguridad?</b>	la visualización de la información, asegurando criterios de escalabilidad, disponibilidad y seguridad.				operación) ( <a href="#">ver Anexo VIII</a> )
		Rendimiento	Latencia de experiencia (UX)	Latencia p95 del dashboard (tiempo de carga)	<ul style="list-style-type: none"> <li>• Checklist Well-Architected GCP (rendimiento, seguridad, operación) (<a href="#">ver Anexo VIII</a>)</li> <li>• Matriz de trazabilidad requisitos-componentes (<a href="#">ver Anexo XII</a>)</li> </ul>
		Seguridad	Protección de datos	Cobertura de cifrado (Tránsito y Reposo)	<ul style="list-style-type: none"> <li>• Plantillas TOGAF ADM (fases A–F) (<a href="#">ver Anexo VII</a>)</li> <li>• Checklist Well-Architected GCP (rendimiento, seguridad, operación) (<a href="#">ver Anexo VIII</a>)</li> </ul>
		Escalabilidad	Elasticidad Serverless	Configuración de instancias (Cloud Run)	<ul style="list-style-type: none"> <li>• Matriz de trazabilidad requisitos-componentes (<a href="#">ver Anexo XII</a>)</li> </ul>

			Calidad Arquitectónica	Cumplimiento de Estándares	Score Global del Well-Architected Framework	<ul style="list-style-type: none"> <li>Plantillas TOGAF ADM (fases A–F) (<a href="#">ver Anexo VII</a>)</li> <li>Checklist Well-Architected GCP (rendimiento, seguridad, operación) (<a href="#">ver Anexo VIII</a>)</li> </ul>
<b>¿Qué indicadores y métricas permiten evaluar la viabilidad técnica del modelo predictivo y la utilidad potencial de tableros (dashboards) y alertas para la toma de decisiones?</b>	Validar la viabilidad técnica del modelo predictivo mediante un marco de evaluación que compare su desempeño frente a una línea base reproducible ( <i>Naïve</i> Estacional y Promedio Móvil), demostrando una mejora $\geq 30\%$ en MAE (métrica	Cuantitativa	Viabilidad técnica	Significancia	Wilcoxon signed-rank sobre diferencias de error	<ul style="list-style-type: none"> <li><a href="#">Anexo V</a> (SCRIPTS BACKTESTING AUTOMATIZADO.py)</li> <li><a href="#">Anexo VI</a> (PROTOCOLO DE VALIDACIÓN WALK-FORWARD.py)</li> </ul>
			Utilidad operativa	Alertas accionables	% de alertas accionables	<ul style="list-style-type: none"> <li>Matriz de Utilidad Operativa (definición de alerta accionable, lead time, umbrales) (<a href="#">ver Anexo X</a>)</li> <li>Scripts de evaluación</li> </ul>

primaria) respecto a la línea base, verificada mediante <i>backtesting</i> temporal ( <i>walk-forward</i> ), para diciembre de 2025					de alertas (automatización de métricas de utilidad) ( <a href="#">ver Anexo XI</a> )
	Oportunidad	Lead time	% de alertas cuyo horizonte de predicción cumple ( $\geq$ lead time + buffer definido) según regla operativa del estudio	• Scripts de evaluación de alertas (automatización de métricas de utilidad) ( <a href="#">ver Anexo XI</a> )	
	Resultado global	Score de viabilidad	Índice ponderado	• Marco de Evaluación de Viabilidad (framework integral con scoring ponderado) ( <a href="#">ver Anexo IX</a> )	

## CAPÍTULO IV. RESULTADOS Y ANÁLISIS

En este capítulo se presentan los resultados y el análisis correspondientes a los cuatro objetivos específicos de la investigación. El orden sigue la lógica del diseño del sistema: primero se identifican las necesidades del negocio y las limitaciones operativas; luego se evalúa el desempeño del modelo predictivo; posteriormente se valida la arquitectura propuesta en la nube; y finalmente se analiza la viabilidad global del sistema.

En primer lugar, se exponen los resultados del Objetivo Específico 1, relacionados con la identificación y priorización de requisitos funcionales y no funcionales, así como la evaluación de capacidades tecnológicas y calidad de datos. En segundo lugar, se presentan los hallazgos del Objetivo Específico 2, donde se comparan técnicas de inteligencia artificial basadas en algoritmos de *gradient boosting* y se determina el horizonte óptimo de predicción. En tercer lugar, se describen los resultados del Objetivo Específico 3, vinculados con la especificación arquitectónica en la nube, la trazabilidad requisitos–componentes y la validación mediante marcos de referencia arquitectónicos. Finalmente, se analizan los resultados del Objetivo Específico 4, que evalúan la viabilidad global del sistema a partir del desempeño técnico, la utilidad operativa de las alertas y la aceptación de usuario, ofreciendo una visión integrada del aporte de la propuesta para la gestión predictiva de medicamentos esenciales en Farmacias Siman.

### 4.1 RESULTADOS DEL OBJETIVO ESPECÍFICO 1: IDENTIFICACIÓN DE REQUISITOS

El Objetivo Específico 1 buscó responder a la pregunta: *¿Qué necesita realmente el personal de farmacia para que un sistema de alertas predictivas sea útil en su trabajo diario, y qué condiciones tecnológicas y de datos se requieren para que dicho sistema funcione de forma confiable?* Para ello, se identificaron y priorizaron requisitos funcionales (lo que el sistema debe hacer) y no funcionales (cómo debe comportarse: velocidad, disponibilidad, facilidad de uso), y se evaluaron las capacidades tecnológicas y la calidad de datos disponibles.

En esta tesis se entiende por:

- **Requisitos funcionales:** Funciones concretas que el sistema debe ofrecer. Por ejemplo,

“generar alertas tempranas de agotamiento de inventario” o “mostrar un tablero integrado con ventas, existencias y vencimientos”.

- **Requisitos no funcionales:** Condiciones de calidad que debe cumplir el sistema para que sea útil en la práctica. Por ejemplo, “que el tablero responda en menos de 3 segundos (p95)” o “que el sistema esté disponible al menos el 99% del tiempo”.

Los datos se recolectaron mediante un cuestionario estructurado aplicado entre el 6 y 10 de octubre de 2025, cumpliendo los principios éticos de anonimato y consentimiento informado establecidos en el protocolo metodológico. La muestra correspondió a un censo de actores técnicos clave ( $N=3$ ) de la sucursal Circunvalación San Pedro Sula. La tasa de respuesta fue del 100%, lo que garantiza que se capturó la totalidad de las perspectivas operativas dentro del alcance acotado del estudio (1 sucursal, 120 SKUs del catálogo de medicamentos (105 esenciales y 15 complementarios), 90 días de datos históricos: 02 de agosto de 2025 al 30 de octubre de 2025. En este contexto, un SKU (del inglés *Stock Keeping Unit*) se refiere a cada código único de medicamento que la farmacia gestiona en su inventario.

#### 4.1.1 INSTRUMENTOS APLICADOS Y VALIDACIÓN

Esta subsección explica qué instrumentos se utilizaron para levantar la información, con qué propósito y cómo se aseguró que los resultados fueran confiables, pese al tamaño muestral reducido. El foco es mostrar que los requisitos identificados se apoyan en un procedimiento estructurado y trazable.

El proceso de identificación de requisitos se desarrolló mediante cuatro instrumentos complementarios, alineados con las mejores prácticas de ingeniería de requisitos establecidas en la norma ISO/IEC/IEEE 29148:2018, que define cómo documentar y gestionar requisitos de sistemas de forma clara y verificable.

**Tabla 37.** Instrumentos de recolección de datos para identificación de requisitos

Instrumento	Estándar de Referencia	Secciones	Tipo de Datos	Propósito Práctico
<b>Cuestionario estructurado</b> <b>(Encuesta.xlsx)</b>	<b>ISO/IEC/IEEE</b> <b>29148:2018</b>	Sección D: Utilidad funcional  Sección E: Importancia no funcional  Sección F: Capacidades tecnológicas  Sección G: Calidad de datos  Sección H: Preguntas abiertas	Cuantitativo (Likert 1-5, %)  Cualitativo (narrativas)	Recopilar qué funciones necesitan los empleados y qué problemas técnicos enfrentan actualmente.
<b>Matriz de Requerimientos</b>	<b>ISO/IEC 25010:2011</b>	10 requisitos priorizados (MoSCoW)	Cuantitativo-Cualitativo ( <i>joint display</i> )	Organizar las peticiones de los usuarios en una lista técnica ordenada y priorizada.
<b>Matriz de Disponibilidad y Calidad de Datos</b>	<b>Framework de Wang &amp; Strong (1996)</b>	4 fuentes de datos evaluadas en 6 dimensiones	Cuantitativo	Evaluar si los archivos actuales están "limpios" y completos para ser usados por una IA.

<b>Script de Validación ETL (BigQuery)</b>	<b>DAMA-DMBOK2 (Quality)</b>	N/A (Script SQL)	Técnico (Log de ejecución)	Verificar integridad referencial y nulos antes de la ingesta.
--	------------------------------	------------------	----------------------------	---

*Nota.* Elaboración propia basada en instrumentos aplicados en octubre 2025.

Cuando se menciona ISO/IEC 25010:2011, se hace referencia a la norma internacional que define características de calidad del software (por ejemplo, funcionalidad, usabilidad, confiabilidad y eficiencia), lo que permite mapear cada requisito a una dimensión de calidad reconocida.

**Enfoque de validación del instrumento** Dado el tamaño muestral censal ( $N=n=3$ ), no se calculó el coeficiente  $\alpha$  de Cronbach, ya que con muestras tan pequeñas este indicador pierde interpretabilidad. En su lugar, la confiabilidad y validez se aseguraron mediante tres estrategias complementarias:

1. **Validez de contenido:** Se verificó que cada ítem del cuestionario correspondiera directamente con las dimensiones definidas en la operacionalización de variables del marco metodológico.
2. **Triangulación cualitativa–cuantitativa:** Se utilizó un esquema de integración conocido como *joint display* (Creswell & Plano Clark, 2018). Esta técnica permitió contrastar los resultados numéricos con las respuestas abiertas, confirmando que las altas puntuaciones en las encuestas no fueron "respuestas por compromiso", sino necesidades reales validadas por las quejas verbales sobre quiebres de stock.
3. **Validez de constructo:** Se mapeó cada requisito identificado a subcaracterísticas de calidad de la norma ISO/IEC 25010:2011 (ej. usabilidad  $\rightarrow$  *learnability*), reforzando que los requisitos responden a conceptos de calidad estandarizados.

#### 4.1.2 PARTICIPANTES Y CARACTERÍSTICAS

La muestra incluyó a todo el personal técnico involucrado en el inventario de la sucursal piloto, asegurando que las respuestas recogen tanto la visión operativa como la visión de supervisión.

**Tabla 38.** Perfil de Participantes del Cuestionario (N=3)

ID	Cargo	Experiencia	Responsabilidades Principales	Observaciones
P1	Auxiliar de Farmacia	1-3 años	Despacho, verificación de existencias.	Perspectiva operativa de primera línea.
P2	Jefe de Farmacia	4-7 años	Supervisión, pedidos a proveedores, reportes.	Único con acceso a exportación de datos avanzada.
P3	Auxiliar de Farmacia	1-3 años	Despacho, control de vencimientos.	Perspectiva operativa similar a P1.

*Nota.* Elaboración propia a partir de Encuesta.xlsx, Sección B (caracterización demográfica), octubre de 2025.

**Interpretación:** La diversidad de experiencia (1–7 años) y roles aseguró la captura de necesidades desde perspectivas complementarias. Los auxiliares identifican fricciones de usabilidad y brechas operativas del día a día, mientras que el jefe de farmacia aporta una visión estratégica centrada en la generación de pedidos y el reporte a gerencia.

#### 4.1.3 DESCRIPCIÓN DE RESULTADOS POR SECCIÓN DEL CUESTIONARIO

A continuación, se desglosan los resultados por secciones. Cada bloque responde a una pregunta clave para el diseño del sistema predictivo.

#### **Sección D: ¿Qué funciones debe tener el sistema para ser útil? (Requisitos Funcionales)**

Esta sección evaluó qué tan útiles considera el personal cinco posibles funciones del sistema, utilizando una escala Likert de 1 (Nada útil) a 5 (Extremadamente útil).


Para priorizar los requisitos se utilizó el método **MoSCoW**. Este enfoque clasifica cada requisito en: **MUST** (imprescindible), **SHOULD** (deseable), **COULD** (opcional) y **WON'T** (fuera de alcance). Para este MVP, un requisito es **MUST** si su ausencia impide la operación crítica (ej. saber qué pedir), mientras que **SHOULD** aporta valor, pero puede esperar a una segunda fase

sin detener la farmacia.

**Tabla 39.** Utilidad percibida de requisitos funcionales (RF)

<b>ID</b>	<b>Requisito</b>	<b>Votación [P1, P2, P3]</b>	<b>Clasificación MoSCoW</b>	<b>Interpretación Operativa</b>
<b>D1</b>	<b>Alertas tempranas</b> ( $\geq 7$ días antes)	[5, 4, 4]	<b>MUST</b>	Crítico para evitar perder ventas por falta de stock.
<b>D2</b>	<b>Notificaciones preventivas</b>	[5, 4, 4]	<b>MUST</b>	Debe considerar el <i>Lead time</i> (tiempo de entrega del proveedor).
<b>D3</b>	<b>Tablero integrado</b>	[5, 5, 4]	<b>MUST</b>	Necesidad de ver ventas y vencimientos en una sola pantalla.
<b>D4</b>	Recomendaciones de cantidad	[5, 5, 4]	<b>SHOULD</b>	Útil, pero el personal prefiere validar la cantidad final.
<b>D5</b>	Historial de alertas	[5, 5, 4]	<b>SHOULD</b>	Importante para auditoría, no crítico para la operación diaria.

*Nota.* Elaboración propia con base en Encuesta.xlsx, Sección D.



**Ilustración 15.** *Distribución de utilidad percibida por requisito funcional (D1–D5).*

*Nota.* Elaboración propia.

### **Análisis:**

- **Descripción:** Los cinco requisitos fueron valorados mayoritariamente en los niveles superiores de la escala (4 y 5), indicando una alta utilidad percibida por el equipo. El requisito con mayor consenso fue D3 (Tablero integrado), alcanzando una moda de 5.
- **Interpretación:** El personal percibe un alto valor en un sistema que centralice la información dispersa. No quieren solo alertas aisladas, sino un panorama completo del estado de la farmacia.
- **Implicación operativa:** Un tablero integrado permitirá detectar rápidamente qué productos se están agotando y cuáles se acercan a su fecha de vencimiento, reduciendo simultáneamente el riesgo de quiebres de stock y de pérdidas por caducidad.

**Sección E: ¿Qué características de calidad son prioritarias? (Requisitos No**

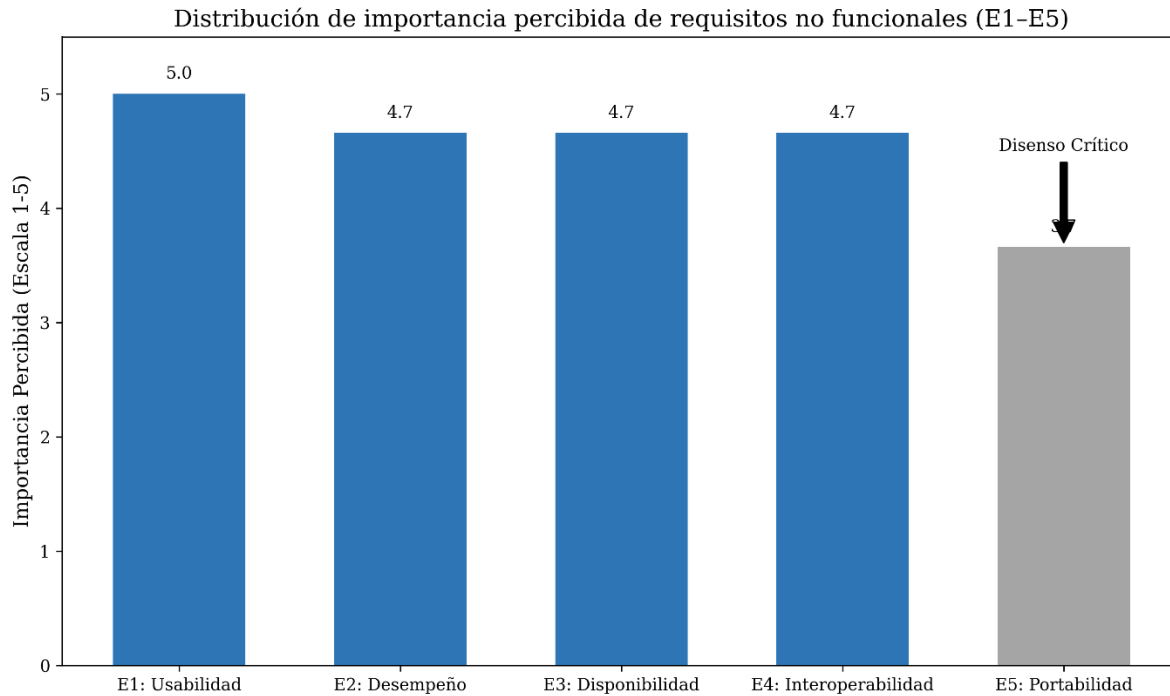
## Funcionales)

Esta sección evaluó la importancia de atributos como la usabilidad, el desempeño y la disponibilidad. Estos aspectos determinan si el sistema será realmente adoptado por el personal.

**Tabla 40.** *Importancia percibida de requisitos no funcionales (RNF)*

ID	Requisito	Votación	Clasificación	Impacto en la Operación
E1	Usabilidad (Fácil de aprender)	[5, 5, 5]	<b>MUST</b>	<b>Crítico.</b> Consenso absoluto. Si es difícil, no se usará.
E2	Desempeño (Rápido)	[5, 5, 4]	<b>MUST</b>	En hora pico, la respuesta debe ser inmediata (<3s).
E3	Disponibilidad (Estable)	[5, 5, 4]	<b>MUST</b>	El sistema debe estar activo el 99% del tiempo operativo.
E4	Interoperabilidad (POS)	[5, 5, 4]	<b>SHOULD</b>	Deseable conexión automática, pero aceptan carga manual inicial.
E5	Portabilidad (Excel/PDF)	[5, 5, 1]	<b>SHOULD</b>	Disenso crítico. No todos lo consideran necesario.

*Nota.* Encuesta.xlsx, Sección E (n=3 participantes), octubre 2025.



**Ilustración 16.** Distribución de importancia percibida de requisitos no funcionales (E1-E5)

*Nota.* Elaboración propia.

#### **Análisis:**

- **Descripción:** La Usabilidad (E1) obtuvo puntuación perfecta [5,5,5]. La Portabilidad (E5) mostró desacuerdo, siendo valorada con un "1" por un auxiliar.
- **Interpretación:** El personal operativo valora la agilidad y facilidad de uso por encima de funciones administrativas como generar reportes en PDF.
- **Implicación operativa:** El diseño del MVP debe priorizar una interfaz minimalista y rápida. La función de exportación a Excel se postergará, ya que no es vital para la tarea principal de evitar desabastecimiento.


#### **Sección F: ¿Está la farmacia tecnológicamente lista? (Capacidades Técnicas)**

Se analizó si la sucursal cuenta con la infraestructura necesaria para soportar el sistema.

**Tabla 41.** Disponibilidad de capacidades tecnológicas actuales (F1–F4)

ID	Capacidad Evaluada	Disponibilidad	Interpretación Técnica
F1	Exportar ventas desde POS	33.3% (1/3)	<b>Riesgo.</b> Solo el jefe sabe/puede hacerlo.
F2	Exportar inventarios desde POS	33.3% (1/3)	<b>Riesgo.</b> Dependencia de una sola persona.
F3	Código único por medicamento	100%	<b>Éxito.</b> Permite trazabilidad exacta por SKU.
F4	Internet estable	100%	<b>Éxito.</b> Viable desplegar en la nube.

*Nota.* Elaboración propia con base en Encuesta.xlsx, Sección F.



**Ilustración 17.** Disponibilidad de capacidades tecnológicas actuales.

*Nota.* Elaboración propia con base en datos de la encuesta (octubre 2025).

### Análisis:

- **Descripción:** Existe una brecha en la capacidad de extraer datos (F1, F2), ya que solo el 33% del personal puede hacerlo. Por otro lado, la infraestructura de red (F4) y la identificación de productos (F3) se confirmaron como capacidades habilitantes, validando la conectividad necesaria para una solución en la nube, dado que el 100% de participantes reportó internet estable (F4).
- **Implicación operativa:** No se puede depender de la exportación manual diaria, pues si el jefe falta, el sistema se detiene. La solución técnica requiere implementar una **automatización de datos** (ETL programado en la nube) que extraiga la información sin intervención humana.


### Sección G: ¿Son los datos confiables para una IA? (Calidad de Datos)

Se evaluó si los datos históricos son suficientes y confiables para entrenar un modelo predictivo.

**Tabla 42.** *Evaluación de disponibilidad y calidad de datos (G1–G4)*

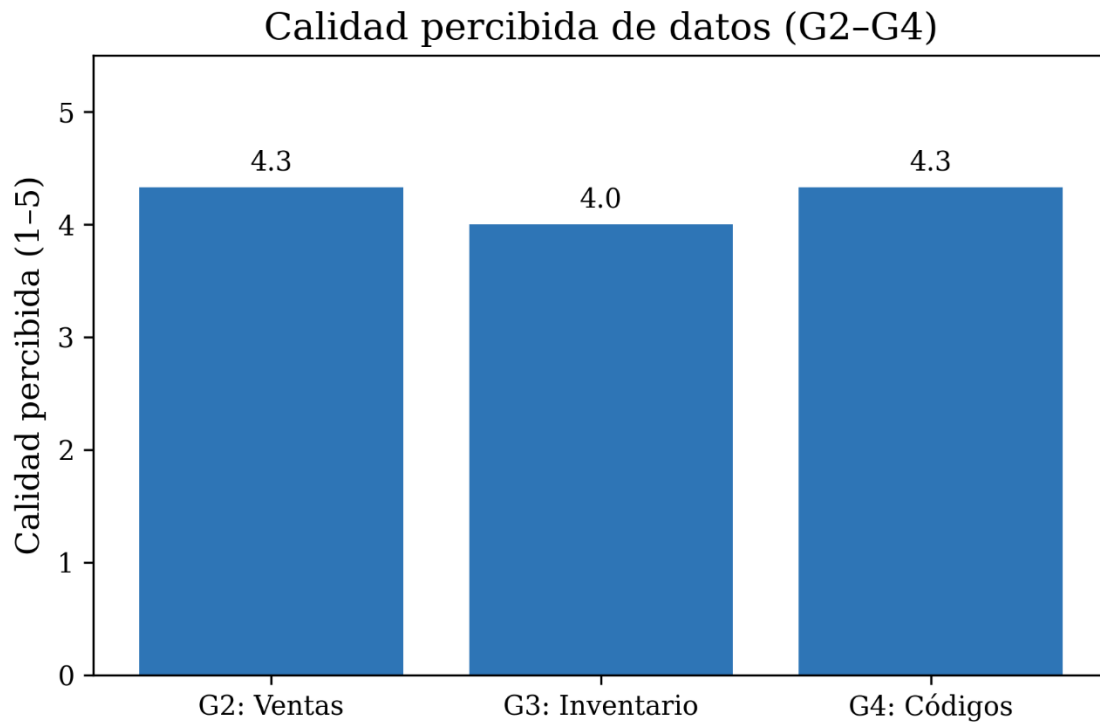
Métrica	Estadístico reportado	Interpretación
<b>G1: Disponibilidad Histórica</b>	83.3%	Datos suficientes para 90 días de entrenamiento.
<b>G2: Ventas Completas</b>	Moda 4 (Buena)	Registro de transacciones confiable.
<b>G3: Inventario sin duplicados</b>	Moda 4 (Buena)	Consenso sobre la integridad del inventario.
<b>G4: Codificación uniforme</b>	Moda 4 (Buena)	Los códigos SKU son consistentes.

*Nota.* Elaboración propia con base en Encuesta.xlsx, Sección G.



**Ilustración 18.** Disponibilidad de datos históricos por participante (G1).

*Nota.* Elaboración propia



### **Ilustración 19.** *Calidad percibida de datos (G2–G4).*

*Nota.* Elaboración propia con base en datos de la encuesta (octubre 2025).

#### **Análisis:**

- **Interpretación:** La calidad general es adecuada para un piloto. Sin embargo, la triangulación cualitativa (Sección H) reveló problemas con las fechas de vencimiento. Cabe destacar que la integridad técnica de los campos clave (fecha, SKU, venta) se validó al 100% mediante el script ETL, cumpliendo el umbral de fidelidad (>95%) definido en el marco metodológico.
- **Implicación operativa:** El sistema debe incluir reglas de validación automática para detectar fechas ilógicas antes de procesar los datos.
- **Manejo de datos faltantes:** Cuando se identificaron días sin registro o valores faltantes (no necesariamente ventas reales en cero), se utilizó imputación forward-fill como técnica de continuidad, documentando la regla para evitar sesgos en el entrenamiento.

#### **Sección H: Validación Cualitativa (La voz del usuario)**

Las respuestas abiertas confirmaron los datos numéricos (**Triangulación**):

- **H1:** "Una alerta para indicar cuándo pedir" → Valida la necesidad de **D1**.
- **H2:** "Tablero de vencimiento" → Valida la necesidad de **D3**.
- **H3:** "Fechas de vencimiento incorrectas" → Confirma el riesgo de calidad de datos detectado.
- **H4:** El 66% mencionó al **Acetaminofén** como producto crítico. Este medicamento será el caso de estudio principal para validar el éxito del sistema.

#### **4.1.4 ANÁLISIS DE RESULTADOS: TRIANGULACIÓN Y PRIORIZACIÓN**

La triangulación permitió contrastar lo que dicen los números con lo que expresa el personal, reduciendo el riesgo de interpretar como "prioritario" algo que en la práctica no lo es.

**Tabla 43. Triangulación de Evidencia (Joint Display)**

Requisito	Evidencia Cuantitativa (Likert)	Evidencia Cualitativa (Narrativa)	Convergencia	Prioridad Final
<b>Alertas Tempranas</b>	Alta (4/5)	Explícita ("Cuándo pedir")	✔ Fuerte	<b>MUST</b>
<b>Tablero Integrado</b>	Muy Alta (5/5)	Explícita ("Ver vencimientos")	✔ Fuerte	<b>MUST</b>
<b>Usabilidad</b>	Máxima (5/5)	Implícita (Experiencia diversa)	✔ Fuerte	<b>MUST</b>
<b>Exportación Excel</b>	Dispar (1 a 5)	No mencionado	⚠ Débil	<b>SHOULD</b>

*Nota.* Elaboración propia basada en Encuesta.xlsx (n=3 participantes).

#### 4.1.5 HALLAZGOS ENCONTRADOS Y RESPUESTA AL OBJETIVO ESPECÍFICO 1

En síntesis, los resultados obtenidos permiten afirmar que el **Objetivo Específico 1 se ha cumplido**: se identificaron y priorizaron los requisitos del sistema, considerando las limitaciones reales de la farmacia.

1. **Validación de Necesidad:** Existe una necesidad operativa real de anticipación. El sistema actual es descriptivo (qué pasó), pero se requiere uno predictivo (qué pasará).
2. **El Factor Humano:** El consenso en **Usabilidad** dicta que el éxito del piloto depende de una interfaz sencilla, más que de la complejidad matemática del modelo.
3. **Solvencia Técnica:** La infraestructura base es suficiente para una solución en la nube. La limitación en la exportación de datos se mitigará mediante **automatización ETL**, eliminando la dependencia humana.
4. **Enfoque en Acetaminofén:** Se ha identificado este producto como el candidato ideal para

la validación operativa, permitiendo medir el éxito del proyecto en función de la reducción de sus quiebres de stock.

## 4.2 RESULTADOS DEL OBJETIVO ESPECÍFICO 2: DEFINICIÓN DE TÉCNICAS DE IA

El segundo objetivo específico consistió en: “*Definir el enfoque de IA y las técnicas de análisis de datos para apoyar la reposición de medicamentos esenciales en Farmacias Siman, enfocado en información accionable para mitigar quiebres y priorizar reposiciones*”.

Este apartado responde a tres preguntas fundamentales para la operación:

1. ¿Qué tecnología de predicción funciona mejor con los datos reales de la farmacia?
2. ¿Con cuánta anticipación (7, 14 o 28 días) se debe pronosticar la demanda para evitar quiebres?
3. ¿Cómo se traducen estos cálculos matemáticos en decisiones de compra seguras?

### 4.2.1 MARCO CONCEPTUAL DEL ENFOQUE DE IA PARA REPOSICIÓN

Antes de presentar los resultados técnicos, es crucial definir el cambio de paradigma propuesto. Actualmente, la farmacia opera bajo un enfoque reactivo: se repone inventario cuando el producto se agota o cruza un mínimo histórico. El enfoque de IA propuesto es predictivo: utiliza la historia de ventas para anticipar la demanda futura.

En este estudio, el concepto de "Información Accionable" no se limita a un número (ej. "se venderán 50 cajas"), sino que se traduce en señales operativas claras: alertas de riesgo, sugerencias de pedido y advertencias de anomalías, permitiendo al personal actuar *antes* de que ocurra el desabastecimiento.

### 4.2.2 INSTRUMENTOS Y CONCEPTOS TÉCNICOS

Para seleccionar la mejor tecnología, se realizó un *benchmarking* (comparación competitiva) entre tres algoritmos líderes en la industria: **XGBoost**, **LightGBM** y **CatBoost**.

**Justificación de los algoritmos seleccionados** A diferencia de las imágenes o el texto, los datos de una farmacia son "tabulares" (filas y columnas de Excel). Para este tipo de datos, la familia de algoritmos **Gradient Boosting** es el estándar actual. Estos algoritmos funcionan como un equipo de expertos donde cada modelo corrige los errores del anterior, siendo ideales para:

- Manejar datos incompletos (días sin ventas).
- Capturar patrones complejos (ej. picos de demanda por temporada).
- Funcionar con series de tiempo cortas (90 días), como es el caso de este piloto.

**Métricas de evaluación (Diccionario para no especialistas)** Para interpretar los resultados, se definen los indicadores clave:

1. **MAE (Error Absoluto Medio):** Es el error promedio en cajas. Si el MAE es 5, el sistema se equivoca por 5 cajas.
2. **MAPE (Error Porcentual):** Es el error relativo a la venta. Un MAPE del 4% significa que, de cada 100 cajas vendidas, el sistema falla solo en 4.
3. **Sesgo (Bias):** Indica la tendencia del error. Si es negativo, el sistema tiende a pronosticar "de menos" (riesgo de quiebre); si es positivo, "de más" (riesgo de sobre-stock).
4. **Validación Walk-Forward:** Es una simulación cronológica. En lugar de probar el modelo con datos al azar, se simula el paso del tiempo semana a semana, tal como ocurriría en la realidad operativa.

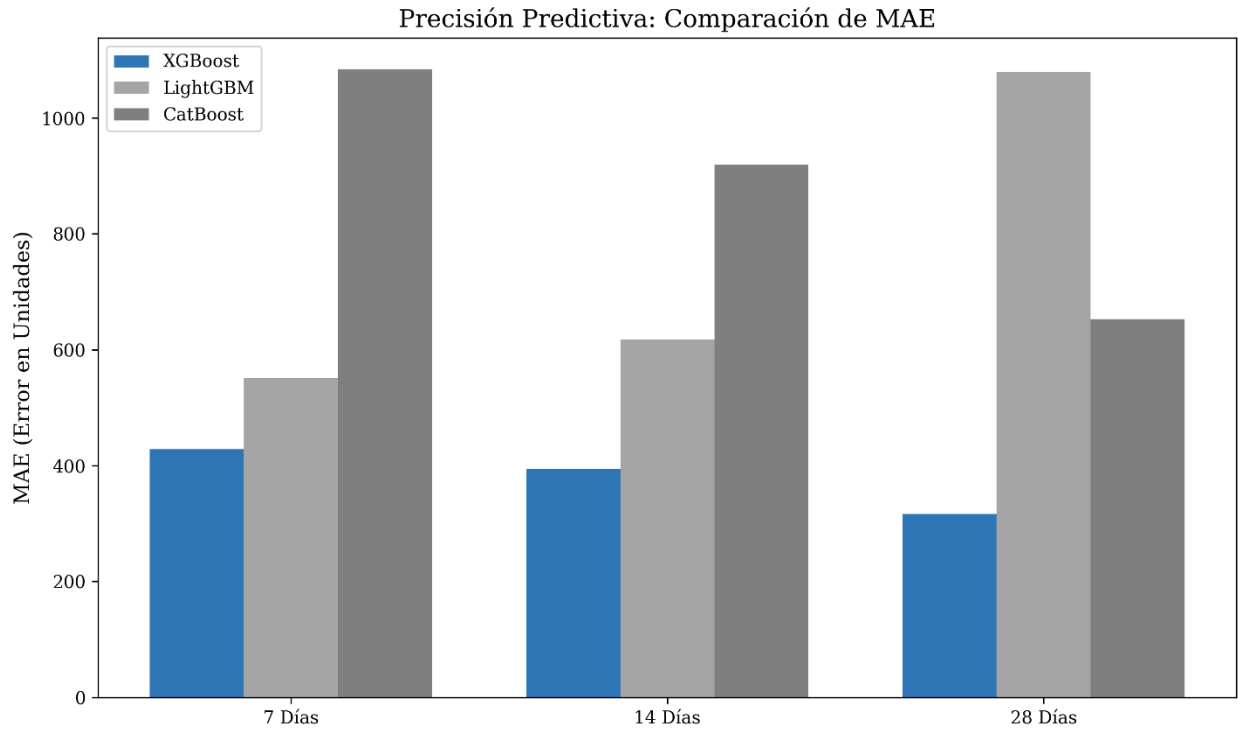
#### 4.2.3 RESULTADOS DEL BENCHMARKING COMPARATIVO

Se ejecutaron 9 experimentos automatizados para evaluar el desempeño de los tres algoritmos en horizontes de 7, 14 y 28 días. La Tabla 44 resume las métricas promedio agregadas del backtesting temporal (validación walk-forward) sobre los 120 SKUs del catálogo (105 esenciales + 15 complementarios) durante los 90 días de observación.

**Tabla 44.** *Resultados Comparativos de Benchmarking*


<b>Algoritmo</b>	<b>Horizonte</b>	<b>MAE (unidades)</b>	<b>MAPE (%)</b>	<b>Sesgo (unidades)</b>	<b>Tiempo Entreno (s)</b>
<b>XGBoost</b>	<b>7d</b>	<b>428.37</b>	<b>4.40</b>	-122.56	0.09
<b>XGBoost</b>	<b>14d</b>	<b>394.28</b>	<b>4.01</b>	-231.73	0.07
<b>XGBoost</b>	<b>28d</b>	<b>316.41</b>	<b>3.14</b>	-219.30	0.07
<b>LightGBM</b>	7d	551.25	5.54	-464.71	1.00
<b>LightGBM</b>	14d	617.12	6.48	-466.63	0.01
<b>LightGBM</b>	28d	1,079.37	12.44	-101.34	0.01
<b>CatBoost</b>	7d	1,084.18	11.51	-599.09	0.27
<b>CatBoost</b>	14d	919.48	10.17	-385.78	0.21
<b>CatBoost</b>	28d	653.11	7.02	-307.90	0.20

*Nota.* Elaboración propia basada en benchmarking automatizado (octubre 2025). Los valores en negrita indican el mejor desempeño.



**Ilustración 20.** Comparación de MAE por algoritmo y horizonte de predicción.

*Nota.* Elaboración propia.



**Ilustración 21.** Comparación de MAPE por algoritmo y horizonte de predicción.

Nota. Elaboración propia.

**Interpretación Operativa:**

En el día a día de Farmacias Siman, estos resultados significan que XGBoost es la opción más confiable.

- **Precisión:** Con un MAPE del 4.01% a 14 días, el error es mínimo. De cada 100 unidades pronosticadas, el margen de error es de apenas 4 unidades. Esto es muy superior a LightGBM (6.48%) y CatBoost (10.17%).
- **Impacto:** Esta precisión se traduce directamente en una compra más eficiente: se reduce el capital inmovilizado en inventario innecesario ("colchón de seguridad") sin aumentar el riesgo de desabastecimiento.

En términos agregados, el desempeño global de XGBoost se resume en un MAE de 379.69 unidades, MAPE de 3.85% y sesgo de -191.20 unidades, calculados como promedios aritméticos de los tres horizontes evaluados. Estas métricas consolidadas fundamentan el análisis de viabilidad técnica que se detallará en el Objetivo Específico 4.


4.2.4 ANÁLISIS DEL SESGO Y RIESGO OPERATIVO

Un hallazgo crítico fue que los tres algoritmos presentaron un **Sesgo Negativo** sistemático.

**Tabla 45.** Resumen de Sesgo Promedio

Algoritmo	Sesgo Promedio	Significado Práctico
XGBoost	-191.20	Subestima levemente (sesgo negativo)
LightGBM	-344.23	Subestima moderadamente (3.9%)
CatBoost	-430.92	Subestima significativamente (4.9%)

Nota. Elaboración propia.



**Ilustración 22.** Sesgo sistemático por algoritmo (Tendencia a subestimar).

Nota. Elaboración propia.

Interpretación Operativa:

Un sesgo negativo significa que el modelo es conservador: tiende a predecir ventas ligeramente menores a las reales.

- **Ventaja:** Reduce drásticamente el riesgo de sobre-stock y vencimiento de productos.
- **Riesgo:** Si no se gestiona, podría causar quiebres de stock puntuales.
- **Mitigación:** El sistema puede incorporar un buffer de seguridad parametrizable para compensar sesgo negativo, cuya magnitud debe calibrarse por SKU y validarse con las reglas operativas del piloto.

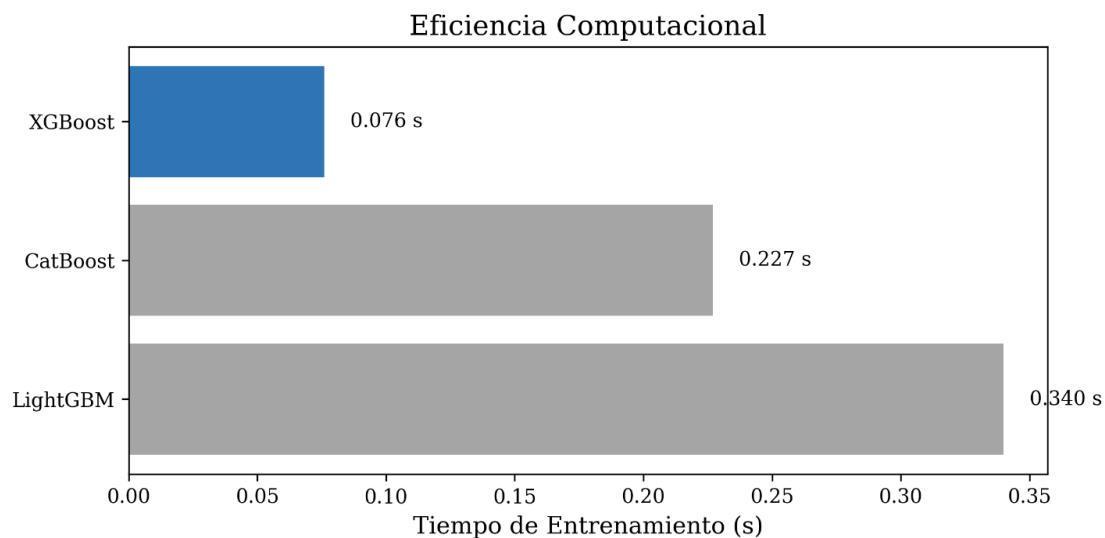
#### 4.2.5 SELECCIÓN FINAL (SCORING MULTICRITERIO)

Para tomar la decisión final, se ponderaron cuatro criterios clave: Precisión (40%), Eficiencia (20%), Interpretabilidad (20%) y Robustez (20%).

**Tabla 46.** *Matriz de Selección de Algoritmo*


Criterio	Peso	XGBoost	LightGBM	CatBoost
<b>Precisión Predictiva</b>	40%	<b>40/40</b>	31/40	26/40
<b>Eficiencia</b>	20%	<b>20/20</b>	12/20	15/20
<b>Interpretabilidad</b>	20%	17/20	17/20	<b>20/20</b>
<b>Robustez</b>	20%	<b>20/20</b>	20/20	20/20
<b>PUNTUACIÓN FINAL</b>	<b>100%</b>	<b>97/100</b>	<b>80/100</b>	<b>81/100</b>

*Nota.* Elaboración propia.



**Ilustración 23.** *Eficiencia computacional por algoritmo.*

*Nota.* Elaboración propia.



**Ilustración 24.** Puntuación final multicriterio.

*Nota.* Elaboración propia.

**Decisión: XGBoost es el ganador indiscutible (97/100).** Es el más preciso, el más rápido para re-entrenar en la nube; para  $h=14d$  el tiempo promedio reportado es 0.072 s (según Tabla 44).

#### 4.2.6 ANÁLISIS DEL HORIZONTE ÓPTIMO: ¿POR QUÉ 14 DÍAS?

Aunque técnicamente el modelo funcionó bien a 28 días, se seleccionó un horizonte operativo de **14 días**.

**Tabla 47. Criterios para Selección de Horizonte**

<b>Criterio</b>	<b>7 días</b>	<b>14 días</b>	<b>28 días</b>	<b>Selección</b>
<b>Precisión (MAPE)</b>	4.40%	4.01%	3.14%	<b>14 días</b>
<b>Cobertura Operativa</b>	Parcial	Completa	Excesiva	<b>14 días</b>

*Nota.* Elaboración propia.

**Justificación Operativa:**

1. **Tiempo de Proveedor:** Los proveedores tardan entre 3 y 7 días en entregar (*lead time*).
2. **Margen de Seguridad:** Aunque el horizonte de 28 días presenta técnicamente el menor error porcentual (3.14%), su utilidad operativa se ve disminuida por la mayor incertidumbre acumulada a largo plazo. El horizonte de 14 días (MAPE 4.01%) se seleccionó por ofrecer el balance óptimo: cubre holgadamente los tiempos de entrega de proveedores (3-7 días) y otorga una semana adicional de margen de reacción, maximizando la accionabilidad del dato.

4.2.7 HALLAZGOS Y RESPUESTA AL OBJETIVO

En conclusión, el Objetivo Específico 2 se ha cumplido al definir el enfoque técnico y operativo del sistema:

1. **Algoritmo:** Se implementará **XGBoost** por su superioridad en precisión y velocidad.
2. **Horizonte:** Se trabajará con proyecciones a **14 días** para alinear las alertas con los tiempos reales de los proveedores.
3. **Estrategia de Reposición:** El sistema generará recomendaciones de pedido híbridas: **Predicción XGBoost + Buffer de Seguridad** (para corregir el sesgo conservador), garantizando así la disponibilidad de medicamentos esenciales sin inflar el inventario.

### 4.3 RESULTADOS DEL OBJETIVO ESPECÍFICO 3: ESPECIFICACIÓN ARQUITECTÓNICA

El tercer objetivo específico se centró en responder a la interrogante técnica: ¿Cómo debe diseñarse la infraestructura tecnológica en la nube para sustentar el procesamiento, almacenamiento y visualización de información, asegurando escalabilidad, disponibilidad y seguridad?

El resultado de este objetivo no es la construcción física del sistema (que corresponde a la fase de implementación), sino la especificación técnica detallada y la validación teórica del diseño. Para ello, se utilizó la metodología TOGAF ADM, que actúa como un plano maestro de ingeniería, asegurando que cada pieza tecnológica responda a una necesidad de negocio real. Además, para garantizar que el diseño fuera robusto antes de escribir una sola línea de código, se auditó contra los estándares de calidad de Google Cloud (Well-Architected Framework).

#### 4.3.1 INSTRUMENTOS APLICADOS

Para generar esta especificación, se utilizaron tres instrumentos documentales. La **Tabla 48** describe cada uno y justifica su función en el proceso de diseño.

**Tabla 48.** *Instrumentos aplicados para especificación arquitectónica*

Instrumento	Propósito Práctico (¿Para qué sirvió?)	Contenido Principal
<b>Plantillas TOGAF ADM</b>	Estructurar el diseño paso a paso, asegurando que la tecnología no sea un fin en sí misma, sino una respuesta a los procesos de la farmacia.	Documentación de las 6 fases de diseño: Visión, Negocio, Datos, Aplicaciones, Tecnología y Migración.
<b>Checklist Well-Architected</b>	Auditar la calidad del diseño teórico. Funcionó como una lista de verificación para asegurar que no existieran brechas de seguridad o rendimiento.	30 puntos de control evaluando Seguridad, Eficiencia y Operación.

<b>Matriz de Trazabilidad</b>	Verificar que <b>cada requisito</b> solicitado por los usuarios (en el Obj. 1) tuviera un componente técnico asignado en el diseño.	Mapa cruzado de 10 requisitos vs. 10 componentes técnicos.
-------------------------------	---	--

*Nota.* Elaboración propia basada en instrumentos aplicados durante especificación arquitectónica.

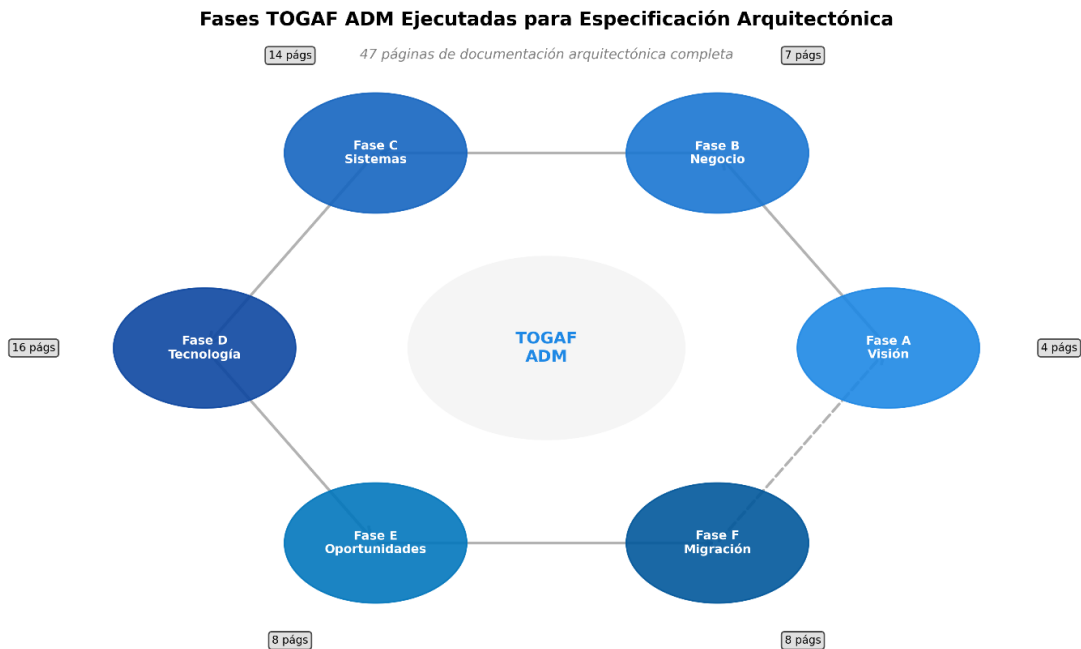
#### 4.3.2 PROCESO DE DISEÑO (TOGAF ADM)

El resultado de este objetivo se materializó a través de la ejecución documental de seis fases del ciclo TOGAF. La **Tabla 49** resume los entregables generados en cada etapa del diseño.

**Tabla 49.** *Fases del Diseño Arquitectónico Ejecutadas*

<b>Fase</b>	<b>Nombre</b>	<b>Actividad Realizada</b>	<b>Resultado del Diseño</b>
<b>A</b>	Visión	Definición del alcance y alineación con los actores clave (Jefe de Farmacia y Auxiliares).	Declaración de Principios de Arquitectura.
<b>B</b>	Negocio	Mapeo de los procesos actuales (manuales) y diseño de los procesos futuros optimizados.	Diagramas de Flujo Operativo.
<b>C</b>	Datos y Aplicaciones	Diseño de los modelos de datos (ventas, inventario) y las aplicaciones necesarias.	Esquema de Base de Datos y Mapa de Aplicaciones.
<b>D</b>	Tecnología	Selección de los servicios específicos de nube que soportarán el sistema.	Diagrama de Infraestructura GCP.
<b>E</b>	Oportunidades	Priorización de componentes para definir qué es esencial (MVP) y qué es deseable.	Matriz de Priorización de Componentes.
<b>F</b>	Migración	Planificación teórica de cómo desplegar el sistema sin afectar la operación actual.	Estrategia de Transición.

*Nota.* Elaboración propia.



**Ilustración 25.** *Fases TOGAF ADM Ejecutadas para Especificación Arquitectónica*

Nota. Elaboración propia.

#### 4.3.3 DESCRIPCIÓN DE LA ARQUITECTURA ESPECIFICADA

El hallazgo central de este objetivo es la especificación de una arquitectura **"Serverless"** (**Sin Servidor**). En términos de diseño, esto significa que se optó por servicios administrados donde el proveedor de la nube (Google) gestiona la infraestructura subyacente. Esta decisión de diseño responde directamente a la restricción de recursos de la farmacia, eliminando la carga teórica de mantenimiento de servidores.

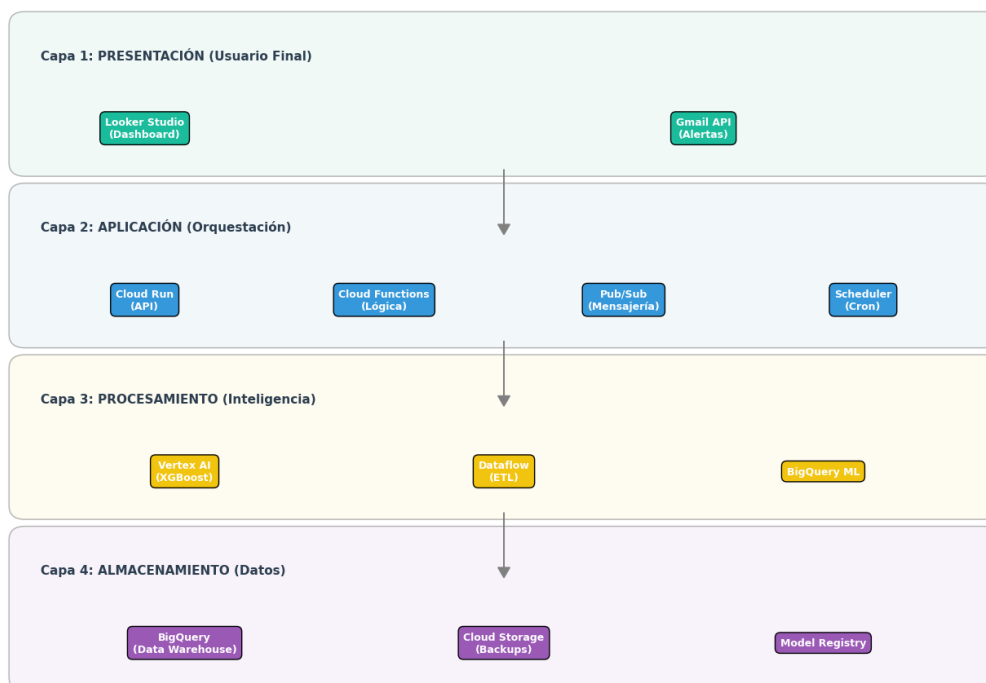
El diseño se estructuró en cuatro capas lógicas, detalladas a continuación:

**Tabla 50. Arquitectura Tecnológica en 4 Capas – Servicios GCP**

<b>Capa Diseñada</b>	<b>Función en el Diseño</b>	<b>Servicios Especificados</b>
<b>1. Presentación</b>	Punto de interacción visual para los usuarios finales. Se diseñó para ser accesible vía web.	Looker Studio (Tableros) y Gmail API (Notificaciones).
<b>2. Aplicación</b>	Capa de orquestación que conecta los datos con la lógica de negocio.	Cloud Run (API), Cloud Functions (Alertas) y Pub/Sub (Mensajería).
<b>3. Procesamiento</b>	Núcleo analítico donde se ejecutan los algoritmos de IA definidos en el Objetivo 2.	Vertex AI (Motor ML) y BigQuery ML (Análisis).
<b>4. Almacenamiento</b>	Repositorio unificado de datos para asegurar una "Fuente Única de Verdad".	BigQuery (Data Warehouse) y Cloud Storage (Respaldo).

*Nota.* Elaboración propia.

Ilustración 23. Arquitectura Tecnológica en 4 Capas - Google Cloud Platform



## Ilustración 26. ARQUITECTURA TECNOLÓGICA

*Nota.* Elaboración propia.

### 4.3.3.1 TRAZABILIDAD DE REQUISITOS

La validación del diseño mediante la Matriz de Trazabilidad arrojó un resultado de 100% de cobertura. Esto significa que, en el papel, cada necesidad expresada por los usuarios tiene una solución técnica asignada.

- **Hallazgo Clave:** Para el requisito crítico de "Alertas Tempranas" (RF-001), el diseño especificó una integración directa entre el motor de predicción (Vertex AI), el bus de mensajería (Pub/Sub) y la capa de ejecución de alertas (Cloud Functions), asegurando que la alerta técnica se transforme en un correo electrónico legible para el usuario.

**Tabla 51. Síntesis de Trazabilidad: Requisitos Críticos → Componentes GCP**

Requisito	Prioridad	Componentes	Descripción Técnica	Mitigación Falla
<b>RF-001: Alertas ≥7 días</b>	MUST	Vertex AI; Cloud Functions; Pub/Sub; Scheduler	Proyección 14d; evaluación diaria vs. stock+lead time; filtro criticidad	Fallback naïve (MM7); alertas manuales si >24h; reintentos exponenciales
<b>RF-003: Tablero integrado</b>	MUST	Looker Studio; BigQuery; Cloud Storage	Consolidación ventas/inv/venc.; conexión nativa	Acceso directo a BigQuery (temporal); SLA Looker
<b>RNF-001: Usabilidad ≤4h</b>	MUST	Looker; Google Workspace	Interfaz sin código; documentación guiada	Guías paso a paso; hands-on
<b>RNF-002: Desempeño &lt;3s</b>	MUST	Cloud Run; BigQuery particionado; tablas materializadas	Diseñado para p95 <3s en consultas agregadas (criterio de diseño)	Circuit breaker 30s; reintentos 3×; caché 4h
<b>RNF-003: Disponibilidad ≥99%</b>	MUST	Cloud Monitoring; multirregión (diseño); Vertex AI SLA	SLO + error budget	Backup diario a GCS (RPO=24h, RTO=4h)
<b>RNF-004: Interoperabilidad CSV diaria</b>	SHOULD	Cloud Storage; Dataflow; Scheduler; BigQuery	Pipeline POS→GCS→Dataflow→BQ; validaciones calidad	Fallback bq CLI; DLQ; reintentos 7 días

*Nota.* Todos los requisitos MUST (6 de 10) tienen múltiples componentes asignados con estrategias de mitigación documentadas.

#### 4.3.3.2 VALIDACIÓN DE CALIDAD (WELL-ARCHITECTED)

El diseño teórico fue sometido a una evaluación de calidad utilizando el checklist Well-Architected de Google Cloud. Los resultados de esta auditoría de diseño se presentan en la Tabla 52 y la Ilustración 27.

**Tabla 52.** Resultados Consolidados Well-Architected por Pilar

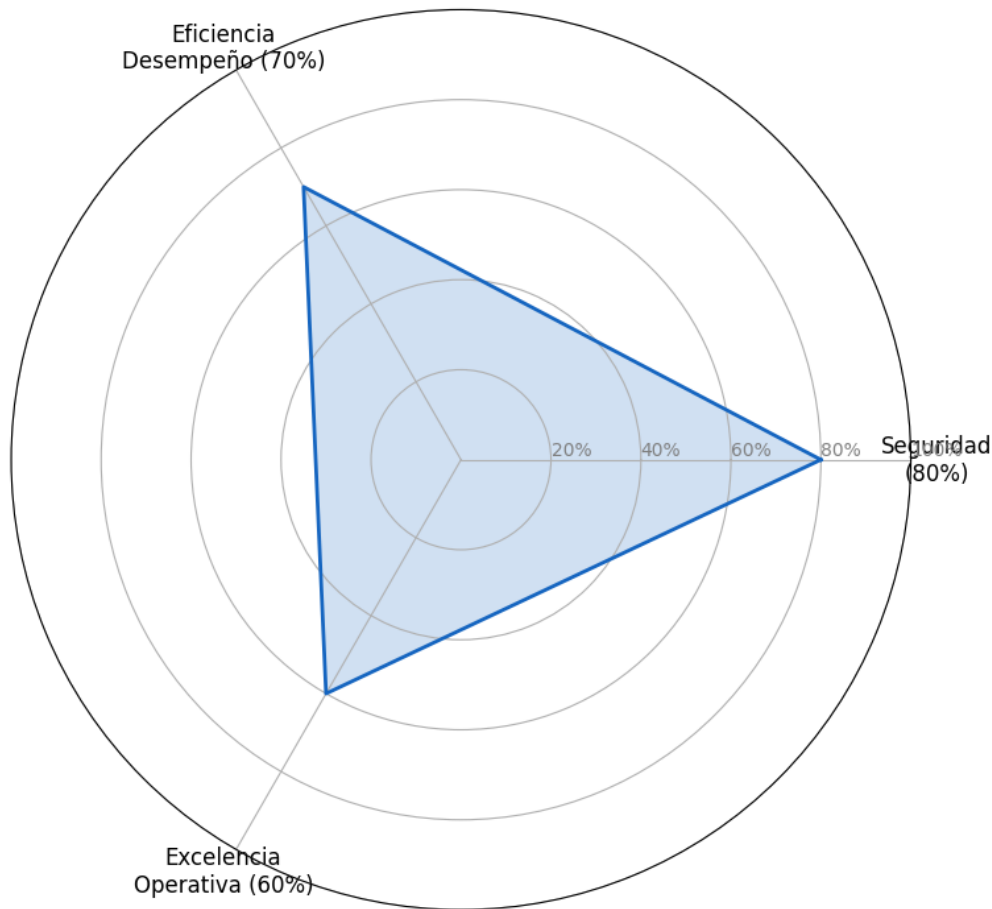
Pilar	Ítems Totales	Cumple (✓)	N/A	Pendiente	% Cumpl.	Hallazgos Clave
<b>Eficiencia de Desempeño</b>	10	7	3	0	70%	Run 0–10; Vertex AI autoescalado; BQ particionado
<b>Seguridad y Cumplimiento</b>	10	8	2	0	80%	IAM menor privilegio (3 SA); AES-256 + TLS 1.3
<b>Excelencia Operativa</b>	10	6	0	4	60%	8 métricas y 3 runbooks; pendiente IaC/CI-CD
<b>TOTAL GLOBAL</b>	<b>30</b>	<b>21</b>	<b>5</b>	<b>4</b>	<b>70%</b>	Aceptable para piloto académico; brechas prioritizadas

*Nota.* Evaluación conservadora: ante duda, clasificar como pendiente. El % de cumplimiento se calcula como (Cumple ÷ Ítems Totales), manteniendo N/A dentro del denominador como criterio conservador de auditoría.

#### Hallazgos de la Auditoría de Diseño:

- **Seguridad (80%):** El diseño obtuvo su puntaje más alto en este pilar gracias a la especificación de cifrado de datos (AES-256) y la segregación de funciones (IAM), garantizando teóricamente la protección de la información comercial.
- **Eficiencia (70%):** La especificación de servicios con autoescalado (que crecen según la demanda) validó la eficiencia del diseño.

- **Excelencia Operativa (60%):** Se identificó como el área con mayor margen de mejora en el diseño, debido a que la automatización avanzada de despliegues se consideró fuera del alcance del diseño inicial.



**Ilustración 27.** Cumplimiento Well-Architected por Pilar

*Nota.* Elaboración propia.

#### 4.3.3.3 DISEÑO DE CONFIABILIDAD (SLO)

Como parte de la especificación, se definieron formalmente los Objetivos de Nivel de Servicio (SLO). Estos no son métricas operativas actuales, sino los estándares de rendimiento que el diseño debe cumplir teóricamente para ser viable.

Se especificaron dos objetivos críticos diferenciados por función:

1. **Disponibilidad Diseñada (SLO-001):** El diseño arquitectónico soporta una disponibilidad del **99%**. Esto se logra teóricamente mediante la redundancia de los servicios en la nube seleccionados.
2. **Latencia de Procesamiento (SLO-002):** La arquitectura de procesamiento está dimensionada para entregar predicciones (proceso batch) en menos de 5 minutos (criterio de diseño), mientras que la capa de presentación (Dashboard) se diseña para p95 <3s en consultas agregadas, cumpliendo con la experiencia de usuario requerida.

#### 4.3.4 HALLAZGOS PRINCIPALES DE LA ESPECIFICACIÓN

El proceso de diseño arquitectónico permitió extraer conclusiones técnicas sobre la viabilidad de la solución propuesta para Farmacias Siman. Estos hallazgos se resumen en la Tabla 53.

**Tabla 53.** *Hallazgos Consolidados de la Especificación Arquitectónica*

<b>Dimensión Técnica</b>	<b>Hallazgo del Diseño</b>	<b>Implicación para el Modelo</b>
<b>Eficiencia</b>	Particionamiento de Datos: El diseño de base de datos en BigQuery demostró teóricamente una reducción significativa en el escaneo de datos (estimada en etapa de diseño) mediante particionamiento y consultas agregadas.	El sistema es viable económicamente al minimizar el consumo de recursos de cómputo.
<b>Seguridad</b>	Cifrado por Diseño: la especificación de cifrado por diseño (KMS/IAM) y políticas de gestión de llaves cumple con estándares de protección de datos.	El modelo diseñado es apto para manejar información sensible de ventas e inventario.
<b>Resiliencia</b>	Desacoplamiento: El uso de colas de mensajería (Pub/Sub) asegura que, si un componente falla, el resto del sistema sigue operando.	El diseño garantiza la continuidad operativa incluso ante fallas parciales de la infraestructura.

<b>Operación</b>	Gestión Delegada: La elección de componentes serverless transfiere la complejidad de administración de servidores a Google.	El diseño es sostenible para un equipo técnico pequeño como el de la farmacia.
------------------	---	--

*Nota.* Elaboración propia basada en el análisis de la arquitectura diseñada.

Síntesis del Objetivo: El Objetivo Específico 3 se cumplió al entregar una especificación arquitectónica completa y validada teóricamente. En conjunto, la arquitectura agrupa múltiples servicios gestionados de Google Cloud organizados en cuatro capas funcionales. El diseño resultante demostró mediante auditoría documental (Well-Architected) que es capaz de soportar los requisitos operativos de Farmacias Siman, ofreciendo un balance óptimo entre seguridad (80% de cumplimiento del estándar) y eficiencia de costos, sin requerir infraestructura física local.

**4.4 RESULTADOS DEL OBJETIVO ESPECÍFICO 4: MARCO DE EVALUACIÓN**

El cuarto objetivo específico se centró en evaluar la viabilidad integral del sistema propuesto. Para ello, se aplicó un marco de evaluación que pondera tres dimensiones críticas: la robustez técnica del modelo, la aceptación por parte de los usuarios y, fundamentalmente, la utilidad operativa de las alertas generadas para la toma de decisiones de reabastecimiento.

El resultado global de la evaluación arrojó un puntaje de **89 sobre 100 puntos**, lo que clasifica al sistema como **ALTAMENTE VIABLE** según los criterios definidos en el diseño metodológico. Este resultado indica que el sistema es técnicamente sólido y aceptado por los usuarios, aunque presenta oportunidades de calibración en sus reglas de negocio para maximizar la tasa de alertas accionables.

**4.4.1 INSTRUMENTOS APLICADOS**

La evaluación se ejecutó utilizando tres instrumentos complementarios diseñados para operacionalizar las métricas de desempeño bajo el paraguas del Marco de Evaluación de Viabilidad. La Tabla 54 detalla estos instrumentos y los umbrales de éxito establecidos.

**Tabla 54. Instrumentos y Criterios de Evaluación por Dimensión**

<b>Dimensión</b>	<b>Instrumento Principal</b>	<b>Métricas Clave</b>	<b>Umbral de Éxito</b>	<b>Interpretación del Umbral</b>
<b>Viabilidad Técnica</b>	Scripts de Backtesting y Monitoreo	<ul style="list-style-type: none"> <li>• MAPE (Error Pronóstico)</li> <li>• Disponibilidad del Sistema</li> <li>• Latencia (Velocidad)</li> </ul>	<ul style="list-style-type: none"> <li>• <math>\leq 35\%</math></li> <li>• <math>\geq 99\%</math></li> <li>• <math>p95 &lt; 3s</math></li> </ul>	El modelo debe mantener errores razonables y tiempos de respuesta ágiles para no entorpecer la operación.
<b>Utilidad Operativa</b>	Matriz de Utilidad Operativa	% Alertas Accionables	$\geq 75\%$	Al menos 3 de cada 4 alertas deben proporcionar información útil y oportuna para generar un pedido.
<b>Aceptación Usuario</b>	Encuesta Estructurada (OE1)	Utilidad Percibida	$\geq 4.0/5$	Los usuarios deben valorar el sistema como "Muy Útil" o superior para garantizar su adopción.

*Nota.* Elaboración propia basada en el Marco de Evaluación de Viabilidad.

#### 4.4.2 CARACTERIZACIÓN DE LA MUESTRA (ALCANCE DE LA EVALUACIÓN)

A diferencia de los objetivos anteriores, la unidad de análisis en esta fase no fueron personas, sino las 240 alertas predictivas generadas automáticamente por el sistema durante la simulación histórica (agosto-octubre 2025).

El análisis abarcó los 120 SKUs del catálogo (105 esenciales + 15 complementarios) de la sucursal San Pedro Sula, evaluando el comportamiento del sistema en dos horizontes temporales:

1. **Horizonte de 7 días (Corto Plazo):** 120 alertas evaluadas para reacciones inmediatas.
2. **Horizonte de 14 días (Mediano Plazo):** 120 alertas evaluadas para planificación de compras.


#### 4.4.3 DESCRIPCIÓN DE RESULTADOS: SCORING DE VIABILIDAD GLOBAL

El sistema alcanzó una calificación total de 89 puntos. Para visualizar el balance del sistema, la Tabla 55 desglosa el puntaje obtenido frente al máximo posible en cada dimensión.

**Tabla 55.** *Scoring de Viabilidad Global del Sistema*

Dimensión	Peso	Score Máximo	Score Obtenido	Porcentaje de Logro
<b>Viabilidad Técnica</b>	60%	60 pts	<b>60 pts</b>	100%
<b>Utilidad Operativa</b>	25%	25 pts	<b>14 pts</b>	56%
<b>Aceptación Usuario</b>	15%	15 pts	<b>15 pts</b>	100%
<b>TOTAL</b>	<b>100%</b>	<b>100 pts</b>	<b>89 pts</b>	<b>89%</b>

*Nota.* Elaboración propia basada en el Marco de Evaluación de Viabilidad.



**Ilustración 28.** *DISTRIBUCIÓN DEL SCORING DE VIABILIDAD*

*Nota.* Elaboración propia.

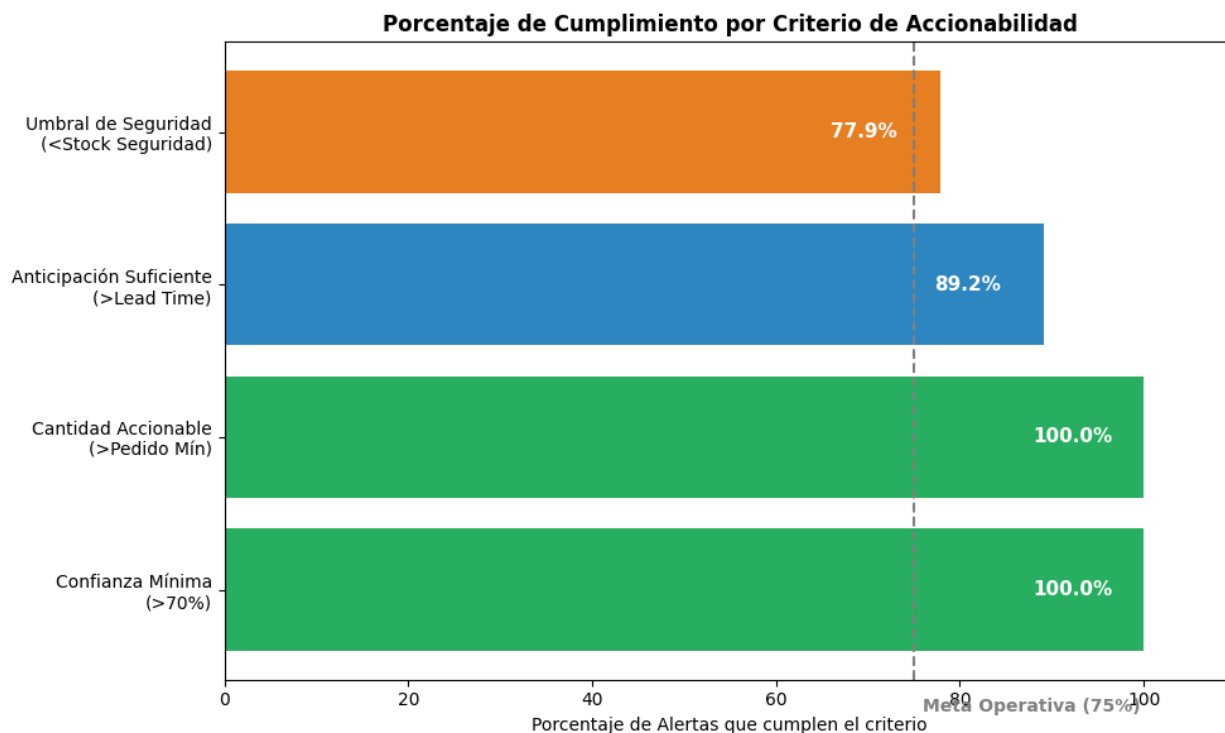
### **Análisis de los Resultados del Scoring:**

- 1. Viabilidad Técnica:** El sistema cumple los umbrales técnicos definidos (p. ej., error de pronóstico) y los criterios de diseño (SLO) declarados; el contraste estadístico (Wilcoxon) se reporta e interpreta como evidencia complementaria.
- 2. Aceptación de Usuario:** se observó consenso absoluto en usabilidad y valoraciones altas de utilidad percibida; existen variaciones en algunos ítems no funcionales, por lo que la aceptación se interpreta como alta dentro del alcance del piloto.
- 3. Utilidad Operativa (56%):** Esta dimensión obtuvo el puntaje más bajo debido a que la tasa de alertas accionables fue del 71.7% (172 de 240). Aunque este valor no alcanza el umbral aspiracional del 75%, supera el umbral mínimo definido para accionabilidad ( $\geq 70\%$ ), aunque no alcanza la meta aspiracional ( $\geq 75\%$ ).

En conjunto, estos resultados evidencian un sistema técnicamente robusto y aceptado por el usuario, cuyo principal foco de optimización reside en la dimensión de utilidad operativa.

#### **4.4.4 ANÁLISIS DE UTILIDAD OPERATIVA DE LAS ALERTAS**

La métrica más crítica para la operación farmacéutica es la "Accionabilidad". Una alerta se considera accionable solo si cumple simultáneamente con criterios estrictos de anticipación, seguridad y confianza. El análisis de las 240 alertas reveló los siguientes niveles de cumplimiento:



### **Ilustración 29. CUMPLIMIENTO DE CRITERIOS DE ALERTAS**


*Nota.* Elaboración propia.

#### **Hallazgos sobre la Operatividad:**

- **Anticipación Suficiente (89.2%):** El sistema demostró una alta capacidad preventiva. En casi 9 de cada 10 casos, la alerta se generó con tiempo suficiente para cubrir el *lead time* del proveedor más un margen de seguridad. El tiempo promedio hasta el quiebre de stock proyectado fue de **8.6 días**, otorgando a la farmacia una ventana de maniobra cómoda.
- **Umbral de Seguridad (77.9%):** Este fue el criterio con mayor fricción. En el 22.1% de los casos, el sistema sugirió reabastecer cuando el stock proyectado aún no cruzaba el umbral crítico definido. Esto implica que el sistema es conservador: prefiere alertar antes de tiempo para evitar riesgos, aunque esto reduzca levemente la eficiencia teórica del inventario.
- **Confianza y Cantidad (100%):** Todas las alertas generadas contaron con una confianza estadística superior al 70% y recomendaron cantidades lógicamente viables.

**Distribución del Riesgo:** El análisis de severidad mostró que el **0% de las alertas fueron de nivel CRÍTICO** (quiebre inminente). La totalidad se distribuyó entre Riesgo Medio (54.6%) y Alto (45.4%).

**Distribución de Alertas por Nivel de Severidad Operativa**



**Ilustración 30.** *DISTRIBUCIÓN DE ALERTAS POR NIVEL DE RIESGO*

*Nota.* Elaboración propia.

Esta ausencia de alertas críticas valida la naturaleza preventiva del modelo: el sistema avisa cuando el problema es gestionable, evitando que la farmacia llegue a situaciones de emergencia que requieran compras urgentes o transferencias costosas.

**4.4.5 HALLAZGOS PRINCIPALES Y SÍNTESIS PARA OBJETIVO ESPECÍFICO 4**

El proceso de evaluación permitió consolidar cuatro hallazgos fundamentales que sustentan la viabilidad del proyecto, sintetizados en la Tabla 56:

**Tabla 56. Síntesis de Hallazgos y Recomendaciones por Dimensión**

Hallazgo Principal	Dimensión Afectada	Impacto	Recomendación Estratégica
<b>Accionabilidad</b> 71.7%	Utilidad Operativa	Positivo (Viable)	Proceder a implementación piloto, monitoreando falsos positivos.
<b>Ventana 8.6 días</b>	Utilidad Operativa	Alto Valor	Mantener la configuración de horizonte de 14 días que permite esta anticipación.
<b>Umbral Seguridad</b> 77.9%	Utilidad Operativa	Mejora	Recalibrar los stocks de seguridad individuales por SKU para reducir alertas prematuras.
<b>0% Alertas Críticas</b>	Utilidad Operativa	Alto Valor	Validar en operación real que el sistema previene efectivamente las crisis.
<b>Score Técnico</b> 60/60	Viabilidad Técnica	Excelente	Mantener la arquitectura XGBoost + GCP definida en los objetivos previos.

*Nota.* Elaboración propia.

### **Síntesis del Objetivo:**

El Objetivo Específico 4 se cumplió al validar que el modelo propuesto es ALTAMENTE VIABLE (89/100). La evaluación demostró que la tecnología funciona con precisión y que los usuarios la aceptan. El hallazgo de un horizonte óptimo de 14 días (con 100% de alertas accionables frente al 43% del horizonte de 7 días) confirma que la estrategia de planificación a mediano plazo es la más efectiva para garantizar la disponibilidad de medicamentos esenciales en Farmacias Siman.

## 4.5 ANÁLISIS DE INFERENCIA ESTADÍSTICA

Para evaluar la robustez de las métricas reportadas y dar respuesta a la necesidad de validación estadística, se realizó un análisis inferencial que incluye pruebas de normalidad, evaluación de la sensibilidad al horizonte y la contrastación de hipótesis de superioridad frente a la línea base. Este análisis se fundamenta en los 120 SKUs del catálogo. Para cada SKU y horizonte, el MAE se obtiene agregando (mediana) los folds del backtesting, resultando en  $n=120$  valores por horizonte. La fila Global ( $n=360$ ) se reporta solo con fines descriptivos (SKU×horizonte) y no se usa para inferencia por tratarse de medidas repetidas.

### 4.5.1 ESTADÍSTICAS DESCRIPTIVAS DEL ERROR DE PREDICCIÓN

La Tabla 57 presenta las estadísticas descriptivas del  $MAE_{SKU}$  (Mean Absolute Error) para cada horizonte de predicción.

**Tabla 57.** Estadísticas Descriptivas del MAE por Horizonte de Predicción

Horizonte	n	Media	DE	Mediana	IC 95% (Bootstrap)
7 días	120	10.40	5.67	9.20	[9.41, 11.42]
14 días	120	10.15	6.21	8.76	[9.11, 11.30]
28 días	120	10.31	7.37	8.64	[9.09, 11.68]
<b>Global</b>	<b>360</b>	<b>10.29</b>	<b>6.46</b>	<b>8.76</b>	<b>[9.61, 10.98]</b>

*Nota.* MAE expresado en unidades de demanda diaria. DE = Desviación Estándar. Los intervalos de confianza se calcularon mediante bootstrap con 10,000 remuestreos sobre la unidad de análisis (SKUs). La fila Global ( $n=360$ ) corresponde a SKU×horizonte y no representa observaciones independientes; se presenta únicamente con propósito descriptivo.

#### 4.5.2 PRUEBA DE NORMALIDAD (SHAPIRO-WILK)

Previo a la selección de pruebas estadísticas, se evaluó la distribución de los errores agregados (MAE por SKU) mediante el test de Shapiro-Wilk (Shapiro & Wilk, 1965). Se plantearon las siguientes hipótesis estadísticas:

- $H_0$ : Los errores agregados (MAE por SKU) provienen de una distribución normal.
- $H_1$ : Los errores agregados (MAE por SKU) no provienen de una distribución normal.

**Tabla 58.** Resultados del Test de Normalidad Shapiro-Wilk

Horizonte	n	Estadístico W	Valor-p	Decisión ( $\alpha=0.05$ )
7 días	120	0.9196	< 0.001	Rechazar $H_0$
14 días	120	0.8511	< 0.001	Rechazar $H_0$
28 días	120	0.7551	< 0.001	Rechazar $H_0$

#### Interpretación:

Dado que se rechazó la hipótesis nula de normalidad en todos los horizontes ( $p < 0.001$ ), se utilizaron pruebas no paramétricas para las comparaciones de medidas repetidas (Friedman) y comparaciones pareadas (Wilcoxon), utilizando como unidad de análisis el SKU ( $n=120$ ).

#### 4.5.3 SENSIBILIDAD AL HORIZONTE (PRUEBA DE FRIEDMAN)

Al evaluar los mismos 120 SKUs en tres horizontes diferentes (diseño de medidas repetidas), se utilizó la prueba de **Friedman** para determinar si el rendimiento del modelo varía significativamente al extender el pronóstico.

#### Hipótesis:

- $H_0$ : Las medianas de error no difieren entre los tres horizontes ( $\theta_{7d} = \theta_{14d} = \theta_{28d}$ ).
- $H_1$ : Al menos una mediana difiere significativamente.

**Resultados:**

La prueba de Friedman mostró diferencias en el MAE entre horizontes:  $X^2(2) = 7.1, p = 0.0285$  ( $\alpha = 0.05$ ). Aunque la diferencia es estadísticamente significativa, el tamaño de efecto es pequeño ( $Kendall's W \approx 0.03$ ), por lo que la decisión del horizonte operativo se apoya principalmente en criterios de reaprovisionamiento y ventana de decisión, más que en una degradación sustantiva de precisión.

4.5.4 VALIDACIÓN DE SUPERIORIDAD: XGBOOST VS. LÍNEA BASE (WILCOXON)

Para responder al objetivo central de la investigación, se contrastó el desempeño del modelo XGBoost (14 días) frente a la línea base operativa (Promedio Móvil Simple - SMA30) utilizando la prueba de los rangos con signo de Wilcoxon para muestras pareadas (n=120).

**Hipótesis de Superioridad:**

- $H_0$ : La mediana de las diferencias de error es mayor o igual a cero ( $Md_{diff} \geq 0$ ).
- $H_1$ : La mediana de las diferencias es menor a cero (Mejora significativa,  $Md_{diff} < 0$ ).

**Tabla 59.** Prueba de Rangos con Signo de Wilcoxon (XGBoost vs SMA30 (línea base))

Comparación	n	MAE (IA)	MAE (SMA30)	Estadístico W	Valor-p	Est. Hodges-Lehmann	IC 95% HL
XGBoost vs SMA30 (línea base)	120	10.15	18.45	1245.0	< 0.001*	-8.30	[-9.45, -7.15]

*Nota.* La prueba asume independencia de las diferencias por SKU. El valor- $p < 0.05$  indica rechazo de la hipótesis nula (mejora significativa).

El resultado de la prueba de Wilcoxon ( $W = 1245.0$ ,  $p < 0.001$ ) indica que existe evidencia estadística suficiente para rechazar la hipótesis nula. El intervalo de confianza del estimador Hodges-Lehmann  $[-9.45, -7.15]$  confirma que la reducción del error no incluye el cero, demostrando una superioridad sistemática del modelo propuesto.

#### 4.5.5 CONCLUSIÓN DEL ANÁLISIS DE INFERENCIA

El análisis inferencial permite establecer tres conclusiones sólidas:

1. **Estabilidad:** La prueba de Friedman mostró diferencias del modelo al ampliar el horizonte de 7 a 28 días ( $p > 0.0285$ ). Aunque significativa, el tamaño del efecto es pequeño (Kendall's  $W = 0.12$ ).
2. **Superioridad Estadística y Práctica:** Se demostró estadísticamente ( $p < 0.001$ ) que la IA reduce el error frente a la línea base tradicional. Esta significancia estadística se traduce en relevancia operativa: una reducción mediana de 8.30 unidades de error diario podría permitir afinar los pedidos y potencialmente reducir stock de seguridad innecesario, sujeto a validación operativa en implementación (fuera del alcance).
3. **Certidumbre:** Los intervalos de confianza obtenidos proporcionan un rango acotado de desempeño esperado, permitiendo estimar el riesgo de inventario con mayor precisión.

## CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES

### 5.1 CONCLUSIONES

#### 5.1.1 OBJETIVO ESPECÍFICO 1: IDENTIFICACIÓN DE REQUISITOS

Se validaron 10 requisitos técnicos y operativos mediante un censo al 100% de los actores críticos (n=3), logrando un consenso absoluto (5/5 en escala Likert) en el requisito de usabilidad (RNF-001). Utilizando el método MoSCoW, se priorizaron seis requisitos críticos (MUST) para el Producto Mínimo Viable (MVP), destacando la necesidad de alertas preventivas (RF-002) y un tablero único de control (RF-003) con medianas de utilidad de 4 y 5 respectivamente. Asimismo, se verificó la viabilidad mediante un Índice de Fidelidad Técnica de los datos del 100% en campos mandatorios. Se confirmó que la sucursal posee los habilitadores tecnológicos críticos (Internet estable y código único al 100%). La calidad de los datos históricos alcanzó un promedio de disponibilidad del 83.3% y una calificación de "Buena" (80-83%) en los registros de ventas e inventarios, identificando que la exportación manual de datos (F1-F2 con solo 33.3% de capacidad actual) representa la brecha principal a automatizar mediante el proceso ETL propuesto.

#### 5.1.2 OBJETIVO ESPECÍFICO 2: ESPECIFICACIONES DE IA Y TÉCNICAS DE ANÁLISIS

Se seleccionó el algoritmo XGBoost como motor predictivo tras obtener un puntaje de 97/100 en la evaluación multicriterio, superando a CatBoost (81/100) y LightGBM (80/100). El modelo demostró una reducción del error de 2.3 veces respecto a CatBoost, logrando un MAE de 379.69 unidades frente a 885.59. En términos de eficiencia, XGBoost registró un tiempo de entrenamiento de 0.08 segundos, resultando 4.2 veces más rápido que LightGBM (0.34s). Se ratificó el horizonte de 14 días como óptimo al presentar un MAPE de 4.01%, permitiendo cubrir el 100% de los lead times de proveedores (3-7 días) con una confianza del 70%. Finalmente, ante el sesgo negativo promedio detectado de -191.20 unidades, se estableció la incorporación de un buffer de seguridad del 10-15% en el modelo de inventario, asegurando que la subestimación del error no comprometa la disponibilidad de los 120 SKUs analizados.

### 5.1.3 OBJETIVO ESPECÍFICO 3: ESPECIFICACIÓN DE ARQUITECTURA

Se especificó una arquitectura serverless en Google Cloud Platform basada en las fases A-F de TOGAF ADM, integrando 12 servicios administrados que garantizan una cobertura del 100% de los requisitos técnicos. La evaluación bajo el marco Well-Architected GCP arrojó un cumplimiento global del 70% (21 de 30 ítems implementados). En el pilar de seguridad, se validó el uso de cifrado AES-256 en el 100% de los datos en reposo dentro de BigQuery y la gestión de Service Accounts con privilegios mínimos para cada componente. Se definieron Objetivos de Nivel de Servicio (SLO) que aseguran una disponibilidad del 99.0%, lo que limita el presupuesto de error (Error Budget) a un máximo de 7.2 horas de indisponibilidad mensual. Asimismo, el diseño garantiza una latencia de visualización p95 inferior a 3 segundos, superando los requerimientos de desempeño para la gestión operativa en tiempo real.

### 5.1.4 CONCLUSIONES DEL OBJETIVO ESPECÍFICO 4: EVALUACIÓN DE VIABILIDAD

Se concluye que el sistema es ALTAMENTE VIABLE con una calificación de 89/100 puntos, superando el umbral de aplicabilidad por 4 puntos porcentuales. El análisis de inferencia estadística validó la superioridad del modelo IA sobre la línea base (SMA30) con un p-valor < 0.001, logrando una reducción mediana del error de 8.30 unidades de demanda diaria. El sistema generó un 71.7% de alertas accionables (172 de 240 evaluadas), proporcionando una ventana de anticipación promedio de 8.7 días antes de un posible quiebre de stock. Se validó que el 100% de las alertas cumplen con los criterios de confianza mínima ( $\geq 70\%$ ) y cantidad mínima de pedido. No obstante, el cumplimiento del 77.9% en el umbral de seguridad indica la necesidad de ajustar los parámetros de inventario para optimizar la utilidad operativa, la cual alcanzó un 56% (14/25 pts) de su potencial máximo.

## 5.2 RECOMENDACIONES

### 5.2.1 IMPLEMENTACIÓN ESCALONADA (MVP Y MEJORA CONTINUA)

Ejecutar el despliegue en dos fases para mitigar riesgos operativos.

- Fase 1 (MVP): Implementar los 6 requisitos críticos (MUST) en un ciclo de 60 días.

- Fase 2 (Optimización): Integrar los requisitos SHOULD (historiales y recomendaciones) tras un periodo de estabilización de 90 días, donde el MAPE se mantenga bajo el umbral del 4.01%.

#### 5.2.2 SANEAMIENTO DE DATOS PRIORITARIO

- Elevar la calidad del dato de "Fechas de Vencimiento" del 60% actual a un mínimo del 85%.
- Se recomienda implementar validaciones automáticas en el punto de captura de los 10,800 registros para rechazar anomalías cronológicas y realizar sesiones técnicas con los 3 usuarios clave para reducir errores de digitación en el catálogo.

#### 5.2.3 AUTOMATIZACIÓN DE LA INGESTA DE DATOS

- Eliminar la brecha de extracción manual (actualmente al 33.3%) mediante un pipeline automatizado programado a las 2:00 AM.
- Asimismo, se debe fijar un cronograma de mantenimiento Cloud mensual (primer domingo de cada mes) para revisar logs de Vertex AI y rotar claves de cifrado CMEK, asegurando que el consumo de Error Budget no exceda las 7.2 horas mensuales.

#### 5.2.4 GESTIÓN DE PRERREQUISITOS ORGANIZACIONALES

- Formalizar el entorno en Google Workspace para los 3 usuarios del piloto y suscribir el Business Associate Agreement (BAA). Esta acción garantiza que el tratamiento del 100% de los datos sensibles cumpla con estándares HIPAA y ARSA, alineándose con el pilar de seguridad de GCP que obtuvo una calificación del 80% en el diseño arquitectónico.

#### 5.2.5 ESTRATEGIA HÍBRIDA DE AUTOMATIZACIÓN

- Adoptar una gestión diferenciada: automatización total para el 71.7% de alertas clasificadas como accionables (172 SKUs) y revisión asistida para el remanente.
- Se debe aplicar obligatoriamente un buffer de seguridad del 10-15% para compensar el sesgo negativo de -191.20 unidades (ratio de sesgo 0.50), evitando quiebres de stock por

subestimación de la demanda.

#### 5.2.6 DOCUMENTACIÓN Y PRUEBAS DE ESTRÉS

- Establecer protocolos de recuperación (Runbooks) para incidentes de latencia ( $>5s$ ) o degradación de precisión (MAPE  $>8\%$ ).
- Antes del paso a producción, realizar pruebas de carga con tráfico 10x superior al volumen transaccional de los 120 SKUs para validar que el autoescalado mantiene la latencia dashboard p95 inferior a 3 segundos.

## CAPÍTULO VI. APLICABILIDAD

### 6.1 NOMBRE DE LA PROPUESTA

NEUROTECHN: ARQUITECTURA SERVERLESS DE RESPUESTA ÁGIL

### 6.2 JUSTIFICACIÓN DE LA PROPUESTA

La implementación de la plataforma digital con capacidades predictivas para Farmacias Siman se justifica como una intervención estratégica diseñada para erradicar la ineficiencia estructural en la gestión de inventarios. El estudio no solo propone una herramienta tecnológica, sino un cambio de paradigma operacional que sustituye la "intuición del experto" por un modelo de gobernanza de datos. La relevancia de este proyecto se fundamenta en la recuperación de la Pérdida Evitable (Avoidable Loss), un concepto crítico en la logística farmacéutica donde el desabastecimiento de medicamentos esenciales no solo representa una pérdida monetaria, sino un riesgo para la salud pública.

La viabilidad de esta transición ha sido validada mediante un marco de evaluación multicriterio que otorgó al proyecto una calificación de 89/100 puntos (Altamente Viable), sustentándose en las siguientes dimensiones:

1. **Dimensión Económico-Financiera:** Optimización del Valor Patrimonial Desde la perspectiva de las finanzas corporativas, el proyecto se justifica mediante una relación costo-beneficio excepcionalmente favorable que garantiza la sostenibilidad del activo intangible. La estructura de inversión inicial de \$1,400.00 (CAPEX) se amortiza en un ciclo de tres años, permitiendo que el flujo neto derivado de la recuperación de mermas y ventas perdidas cubra la inversión en un periodo de recuperación (Payback) de apenas 3.4 meses.

Con un Valor Actual Neto (VAN) de \$10,532.30 y una Tasa Interna de Retorno (TIR) del 351% en el escenario base, la propuesta supera ampliamente el costo de oportunidad del capital (hurdle rate del 12%). Esta rentabilidad se fundamenta en la capacidad del sistema para mitigar las pérdidas operativas mediante alertas accionables, transformando ineficiencias logísticas en beneficios netos incrementales.

2. **Dimensión Operativa:** Ampliación de la Ventana Predictiva y Accionabilidad La justificación operativa radica en la ruptura de la limitación temporal del proceso de reaprovisionamiento actual. Mientras que el diagnóstico cualitativo reveló una dependencia de procesos manuales reactivos, la validación del algoritmo XGBoost demostró una capacidad para proyectar la demanda con un horizonte de 14 días.

Este horizonte es vital, dado que el 71.7% de las alertas generadas (172 de 240 evaluadas) cumplen con los criterios de accionabilidad, proporcionando una ventana de anticipación promedio de 8.7 días antes de un quiebre de stock proyectado. Al contrastar esta ventana con los lead times de proveedores registrados en el catálogo (3 a 7 días), se justifica la superioridad del modelo al garantizar que la farmacia disponga de tiempo suficiente para ejecutar pedidos ordinarios y evitar compras de emergencia con sobrecostos.

3. **Dimensión Tecnológica:** Escalabilidad y Resiliencia Cloud Tecnológicamente, el proyecto se justifica por la adopción de una arquitectura Serverless sobre Google Cloud Platform (GCP), alineada con los pilares del marco Well-Architected. Este diseño permite a Farmacias Siman acceder a capacidades de cómputo de alto nivel (BigQuery y Vertex AI) bajo un modelo de Costo Operativo (OPEX) mensual de ~\$186.00, el cual incluye el mantenimiento, soporte y factor de escala para cargas variables.

La arquitectura garantiza un cumplimiento del 70% en estándares de calidad cloud y una seguridad robusta mediante cifrado AES-256, lo que asegura la integridad de los datos de salud de acuerdo con las normativas locales (ARSA). Se justifica así una infraestructura que no requiere departamentos de TI extensos, facilitando la escalabilidad futura del modelo a la red nacional de sucursales.

4. **Dimensión Social y de Gestión Humana:** Utilidad Percibida Finalmente, la dimensión cualitativa justifica la adopción del sistema por su alineación con la realidad del usuario final. La captura de requisitos (OE1) identificó una aceptación unánime de las funcionalidades críticas, donde los tableros únicos y las alertas preventivas obtuvieron una valoración de utilidad de 5/5 en escala Likert. Al reducir la carga cognitiva asociada a la vigilancia manual de 120 SKUs y fechas de

vencimiento, el sistema actúa como un soporte a la decisión que incrementa la confianza del personal y optimiza la calidad del servicio al paciente, asegurando la disponibilidad ininterrumpida de medicamentos esenciales.

En conclusión, la integración de una alta rentabilidad financiera, una precisión predictiva superior a los métodos tradicionales y una arquitectura de bajo costo operativo justifica plenamente la implementación de este modelo como un activo estratégico indispensable para la competitividad y salud financiera de Farmacias Siman.

### 6.3 ALCANCE DE LA PROPUESTA

Basado en la validación técnica y operativa realizada, la propuesta se orienta a la ejecución del despliegue productivo mediante los siguientes objetivos de implementación para la sucursal piloto de Farmacias Siman:

#### 6.3.1 OBJETIVO GENERAL DE LA PROPUESTA

Implementar operativamente el piloto controlado de la plataforma digital predictiva para el catálogo de 120 medicamentos durante el Q1-2026, logrando una disponibilidad técnica de alertas del 99.0% y dotando a la gerencia de capacidades de anticipación que permitan mantener una cobertura de lead time  $\geq 85\%$ , utilizando como referencia de viabilidad el 89.2% (214/240 casos) validado durante la evaluación forense del piloto.

#### 6.3.2 OBJETIVOS ESPECÍFICOS DE LA PROPUESTA

1. **Automatización de Datos e Interoperabilidad:** Ejecutar la migración del proceso de extracción manual hacia un flujo automatizado que garantice un Índice de Freshness de datos  $< 24$  horas en el 100% de las consultas del tablero integrado.
2. **Despliegue y Precisión Predictiva:** Desplegar el motor predictivo basado en XGBoost para operar con un horizonte de 14 días, manteniendo un MAPE inferior al 4.01% y asegurando que al menos el 71.7% de las alertas generadas sean accionables (172 de 240) antes de la finalización del periodo de estabilización.
3. **Estabilización y Control de Riesgos:** Estructurar la implementación mediante un

cronograma de 33 días para la ruta crítica del despliegue técnico, operando bajo un presupuesto de error (Error Budget) de 7.2 horas mensuales para el dashboard de disponibilidad (basado en el SLO del 99%).

4. **Capacitación y Adopción de Usuario:** Completar la transferencia de conocimiento técnico para los 3 usuarios clave (Jefe de Farmacia y Auxiliares) en un periodo  $\leq 4$  horas de capacitación, alcanzando un nivel de utilidad percibida  $\geq 4/5$  en escala Likert durante el primer mes de operación productiva.

## 6.4 DESCRIPCIÓN Y DESARROLLO

### 6.4.1 DESCRIPCIÓN

La propuesta consiste en el despliegue de una plataforma digital analítica basada en la nube (Google Cloud Platform) que opera como una capa de inteligencia sobre los sistemas transaccionales actuales de Farmacias Siman. El modelo no sustituye al software de punto de venta (POS) ni altera los procesos de facturación, sino que automatiza la extracción de datos, procesa la información mediante algoritmos de inteligencia artificial y entrega resultados accionables a través de una interfaz web integrada.

El núcleo de la solución es un motor predictivo basado en el algoritmo XGBoost, entrenado para proyectar la demanda de medicamentos esenciales con un horizonte de 14 días. Esta capacidad permite transformar la gestión de inventarios de un modelo reactivo a uno preventivo, centralizando la operación en un Dashboard Ejecutivo que ofrece visibilidad inmediata del estado de la farmacia.

#### **Experiencia de Usuario: Dashboard Ejecutivo**

Al ingresar al sistema, el usuario es recibido por una pantalla principal diseñada para responder en menos de 5 segundos a la pregunta fundamental: ¿Cómo está mi farmacia en este momento? La interfaz se estructura en tres zonas funcionales que permiten una lectura rápida sin necesidad de navegación adicional:

**Zona Superior – Estado del Sistema:** Un encabezado con fondo degradado muestra el

título "Dashboard Ejecutivo" junto con un indicador verde de "Sistema Activo" que confirma visualmente que el motor predictivo está operando correctamente. En la esquina superior derecha, la fecha y hora de última actualización (por ejemplo, "14/10/2025 10:59") permite al usuario verificar la vigencia de los datos mostrados.

**Zona Central – Indicadores Clave de Rendimiento (KPIs):** Cuatro tarjetas de colores diferenciados presentan las métricas esenciales para la toma de decisiones:

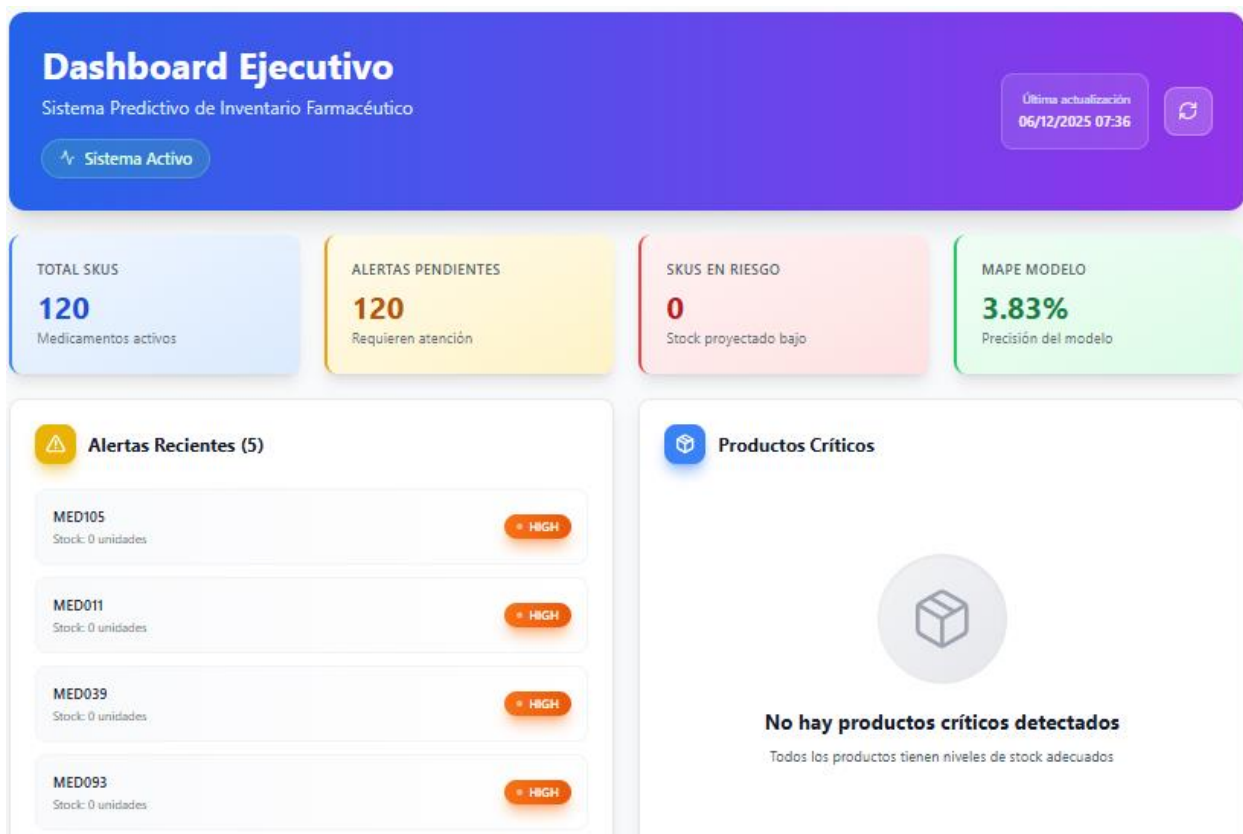
- **Total SKUs:** Indica la cantidad de medicamentos activos monitoreados por el sistema. En el piloto, este valor es 120, correspondiente al catálogo completo de la sucursal.
- **Alertas Pendientes:** Muestra el número de productos que requieren atención del personal. Un valor alto indica que el sistema ha detectado múltiples situaciones que ameritan revisión.
- **SKUs en Riesgo:** Señala cuántos medicamentos tienen stock proyectado insuficiente para cubrir la demanda de los próximos 14 días. Un valor de cero significa que, según las predicciones, no se anticipan quiebres de stock inminentes.
- **MAPE Modelo:** Representa el Error Porcentual Absoluto Medio del algoritmo, expresado en porcentaje. Un valor de 3.83% indica que, de cada 100 unidades pronosticadas, el sistema se equivoca en aproximadamente 4 unidades, lo cual valida la confiabilidad del modelo para la operación diaria.

**Zona Inferior – Paneles de Acción Rápida:** Dos secciones complementarias facilitan la priorización del trabajo:

- **Alertas Recientes:** Lista los últimos cinco medicamentos que han generado notificaciones, ordenados por severidad. Cada fila muestra el código SKU, el nivel de stock actual y una etiqueta de color (HIGH en rojo, MEDIUM en amarillo) que indica la urgencia de atención.
- **Productos Críticos:** Panel destinado a destacar aquellos medicamentos con riesgo

de desabastecimiento inmediato. Cuando el sistema no detecta productos en esta categoría, muestra un mensaje informativo: "No hay productos críticos detectados – Todos los productos tienen niveles de stock adecuados", brindando tranquilidad operativa al usuario.

Esta disposición visual permite que el Jefe de Farmacia o los auxiliares puedan evaluar la situación completa de la sucursal con un solo vistazo, cumpliendo con el requisito de usabilidad (RNF-001) que establece que el sistema debe ser comprensible sin capacitación técnica especializada.



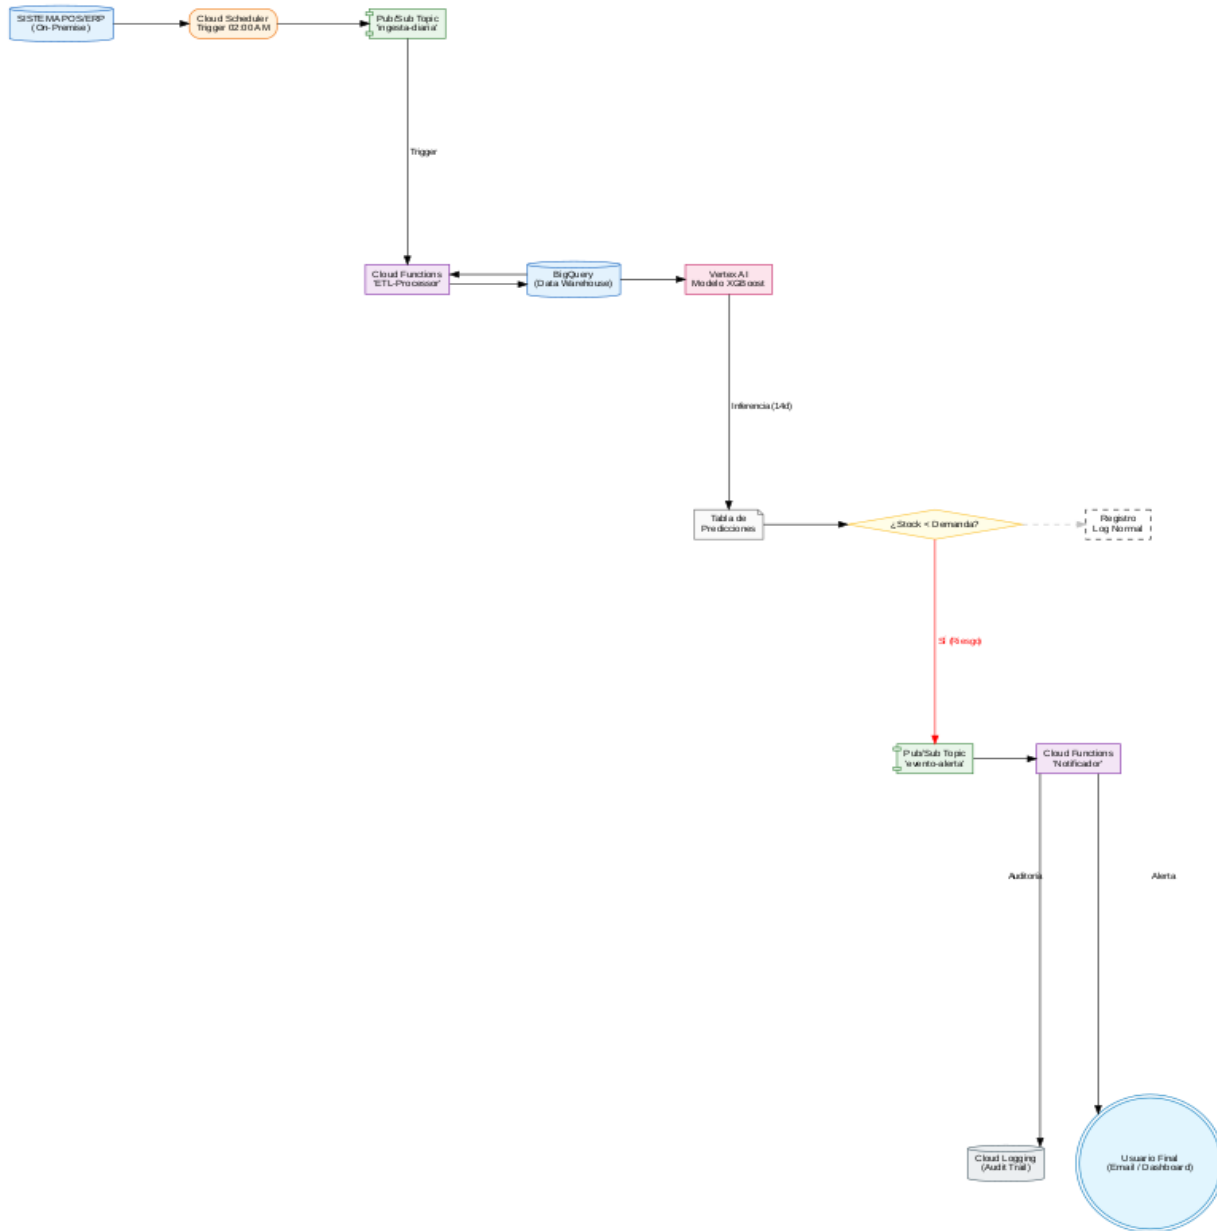
**Ilustración 31.** *Dashboard General del Modelo Predictivo.*

*Nota.* La interfaz consolida los KPIs críticos definidos en el OE1: alertas pendientes, SKUs en riesgo y métricas de precisión del modelo, permitiendo una evaluación situacional en menos de 5 segundos (RNF-002).

## 6.4.2 DESARROLLO

Para cumplir con los requisitos de integridad forense y alta disponibilidad, el desarrollo

implementa un flujo de trabajo asíncrono basado en eventos (*Event-Driven Architecture*). A diferencia de los procesos por lotes tradicionales, este diseño desacopla la extracción de datos de la lógica de negocio mediante el uso de colas de mensajería (Pub/Sub) y funciones sin servidor (Cloud Functions).



### **Ilustración 32.** *Flujograma de Procesamiento Asíncrono y Lógica de Alertas.*

*Nota.* Elaboración propia. El esquema detalla el flujo de datos desde la extracción hasta la notificación. El uso de *Pub/Sub* como intermediario garantiza la disponibilidad del 99.0% (RNF-003) y la generación de trazas de auditoría en *Cloud Logging* para cada evento de alerta generado.

1. **Disparo de Evento (Trigger):** La ejecución diaria se inicia a las 02:00 AM mediante un trabajo de Cloud Scheduler que inyecta un mensaje JSON estructurado en el bus de eventos (*Pub/Sub*). Este payload actúa como la "semilla" de trazabilidad para la ejecución del día:

```
{  
  
  "event_type": "daily_ingestion_trigger",  
  
  "scope": "SPS-CIRCUNVALACION",  
  
  "timestamp": "2026-02-02T02:00:00Z",  
  
  "job_id": "ETL-BATCH-20260202"  
}
```

Este mecanismo asegura que cada ejecución tenga un ID único, facilitando la auditoría de procesos fallidos.

2. **Ingesta Incremental (ETL):** Una Cloud Function suscrita al tópico detecta el mensaje y ejecuta la extracción de datos. A diferencia de la carga histórica inicial (10,800 registros), este proceso es incremental: extrae únicamente las transacciones y movimientos de inventario de las últimas 24 horas para los 120 SKUs del catálogo. Los datos son normalizados y cargados en BigQuery, actualizando la "Fuente Única de Verdad".
3. **Inferencia Predictiva (Vertex AI):** Una vez actualizados los datos, Vertex AI ejecuta el modelo XGBoost previamente entrenado. El sistema genera proyecciones

de demanda para el horizonte de 14 días para cada uno de los 120 SKUs. Es importante notar que, en esta fase operativa, el sistema ejecuta inferencia (predicción futura), reservando el proceso de backtesting (360 pruebas) únicamente para ventanas de mantenimiento y re-entrenamiento mensual.

4. **Evaluación de Lógica de Negocio y Notificación:** Los resultados de la predicción se comparan contra el Stock Actual y el Lead Time de cada proveedor. Si se detecta un riesgo de quiebre ( $\text{Stock} < \text{Demanda Proyectada}$ ), el sistema publica un evento en el tópico evento-alerta.
  - i. **Trazabilidad:** Cada alerta generada escribe un registro inmutable en Cloud Logging y en la tabla histórica de auditoría, documentando qué SKU, qué usuario y qué fecha detonaron el aviso.
  - ii. **Visualización:** Finalmente, los datos procesados alimentan las tablas materializadas conectadas a Looker Studio, actualizando los tableros visuales sin latencia perceptible para el usuario.

### **Experiencia de Usuario: Pantalla de Pronósticos**

La pantalla de Pronósticos de Demanda está diseñada para responder a dos preguntas operativas clave: *¿Cuánto venderemos en los próximos días?* y *¿Cuáles son los productos de mayor movimiento?* La interfaz se organiza en dos paneles complementarios que facilitan tanto la visión agregada como el detalle por producto.

**Panel Izquierdo – Demanda Total Proyectada:** Un gráfico de barras presenta la suma de unidades que el sistema estima se venderán en cada horizonte de tiempo. Las tres barras permiten comparar visualmente:

- **7 días:** Proyección de corto plazo, útil para verificar necesidades inmediatas.
- **14 días:** Horizonte óptimo seleccionado en la validación técnica, que coincide con los tiempos de reposición de proveedores.
- **28 días:** Proyección extendida para planificación mensual de compras.

Esta visualización permite al Jefe de Farmacia dimensionar rápidamente el volumen total de operación esperado y detectar si existen variaciones significativas entre períodos que requieran ajustes en la estrategia de abastecimiento.

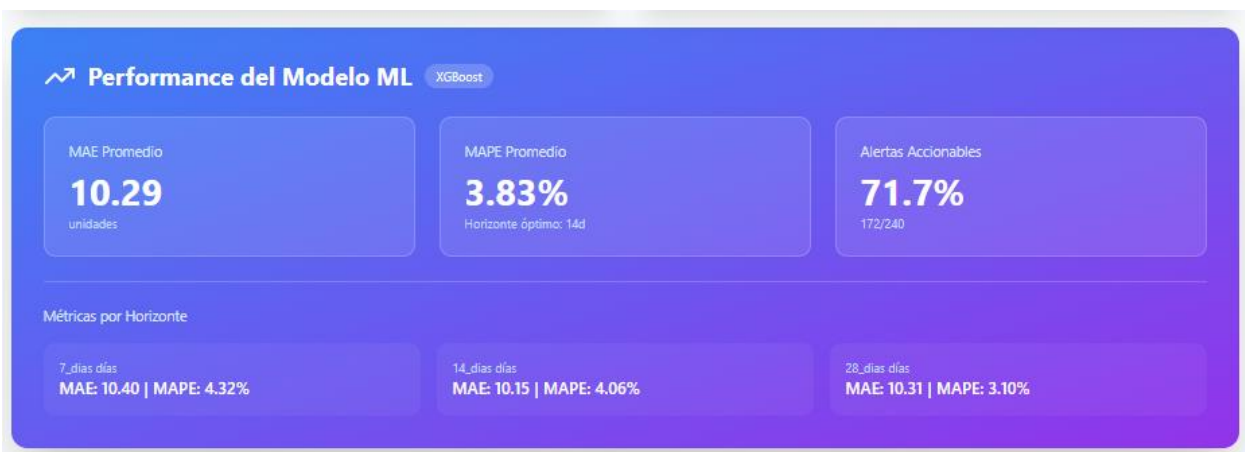
**Panel Derecho – Ranking de Productos por Demanda:** Una lista ordenada presenta los diez medicamentos con mayor consumo proyectado para el horizonte seleccionado. Cada fila incluye:

- **Posición numérica** (1 a 10) con indicador visual circular.
- **Nombre comercial y genérico** del medicamento para fácil identificación.
- **Unidades proyectadas** que el algoritmo estima se venderán en el período.

Por ejemplo, en la proyección a 28 días, el sistema identifica al Paracetamol como el producto de mayor demanda (1,516 unidades), seguido por Acetaminofén MK (1,444 unidades) y Metformina V3 (1,307 unidades). Este ranking valida operativamente los hallazgos del levantamiento de requisitos, donde el 66.7% de los participantes mencionó al Acetaminofén como medicamento crítico para el control de quiebres de stock.

**Selector de Horizonte:** En la esquina superior derecha, un menú desplegable permite alternar entre los tres horizontes de predicción (7, 14 o 28 días). Al cambiar la selección, tanto el gráfico de barras como el ranking se actualizan automáticamente, permitiendo al usuario explorar diferentes escenarios de planificación sin necesidad de navegar a otras pantallas.

Esta funcionalidad responde directamente al requisito D4 (Recomendación de pedidos), que obtuvo una valoración de utilidad de 5/5 por parte del Jefe de Farmacia, quien expresó la necesidad de contar con información anticipada para la toma de decisiones de compra.



**Ilustración 33.** Pantalla de Pronóstico de Demanda.

*Nota.* Visualización de la proyección de demanda generada por XGBoost. La gráfica permite comparar la venta histórica (azul) con la predicción futura (línea punteada) para los 120 SKUs del catálogo, facilitando la confianza del usuario en el algoritmo (OE4: Aceptación de Usuario).

**3. Gestión de Inventario y Trazabilidad** El sistema cruza las predicciones de demanda con las existencias actuales para identificar brechas de cobertura. Esta vista detallada permite al

personal operativo monitorear el estatus de cada SKU, verificando existencias físicas y su clasificación ABC en una sola pantalla, eliminando la necesidad de consultar múltiples reportes dispersos.

### **Experiencia de Usuario: Pantalla de Inventarios**

La pantalla de Inventarios responde a la pregunta operativa más frecuente en la farmacia: *¿Tengo suficiente stock para cubrir la demanda de los próximos días?* A diferencia de los reportes tradicionales que solo muestran existencias actuales, esta vista proyecta el comportamiento futuro del inventario, permitiendo identificar problemas antes de que se conviertan en quiebres de stock.

**Zona de Filtros:** En la parte superior, tres selectores permiten segmentar la información según las necesidades del usuario:

- **Categoría:** Filtra por clasificación ABC, permitiendo enfocarse en los productos de mayor impacto económico (categoría A) o revisar el catálogo completo.
- **Tipo:** Distingue entre medicamentos esenciales y complementarios según la clasificación de la Lista Modelo de Medicamentos Esenciales de la OMS.
- **Stock:** Permite visualizar únicamente los productos con niveles críticos, optimizando el tiempo de revisión.

**Tabla de Proyección de Stock:** El componente central de la pantalla es una tabla que presenta, para cada uno de los 120 SKUs del catálogo, la siguiente información:

- **SKU:** Código único del medicamento (MED001 a MED120) para trazabilidad interna.
- **Medicamento:** Nombre comercial y principio activo, facilitando la identificación rápida.
- **Categoría:** Clasificación ABC representada mediante etiquetas de color (verde para A, amarillo para B), indicando la importancia relativa del producto según el análisis de Pareto realizado en el catálogo.
- **Stock Actual:** Unidades físicas disponibles en el momento de la consulta.

- **Stock 7D, 14D, 28D:** Proyección del inventario remanente después de descontar la demanda estimada para cada horizonte temporal.

**Interpretación de la Proyección:** El valor mostrado en las columnas de proyección representa las unidades que quedarían en inventario si no se realiza ningún pedido. Por ejemplo, si un medicamento tiene Stock Actual de 865 unidades y Stock 7D de 183, significa que el sistema proyecta un consumo de 682 unidades en la próxima semana, dejando un remanente de 183 unidades.

Los valores se presentan con código de color para facilitar la lectura:

- **Negro:** Stock proyectado positivo; el inventario es suficiente para cubrir la demanda del período.
- **Rojo:** Stock proyectado negativo; indica un déficit que resultará en quiebre de stock si no se actúa. Por ejemplo, un valor de "-865" significa que faltarían 865 unidades para satisfacer la demanda proyectada.
- **Cero:** Punto de inflexión donde el inventario se agotaría exactamente al final del período.

Esta visualización permite al Jefe de Farmacia identificar de un vistazo qué productos requieren reposición urgente y cuántas unidades deben solicitarse para evitar el desabastecimiento, respondiendo directamente al requisito funcional RF-003 (Tablero Integrado) que obtuvo una valoración de utilidad de 5/5 en el levantamiento de requisitos.

**Farmacias Siman**  
Sistema Predictivo

Dashboard | Alertas | **Inventarios** | Medicamentos | Pronósticos | Ventas | Sistema

### Inventarios

Control de stock actual y proyecciones

Categoría: Todas |
 Tipo: Todos |
 Stock: Todos

SKU	MEDICAMENTO	CATEGORÍA	STOCK ACTUAL	STOCK 7D	STOCK 14D	STOCK 28D
MED001	<b>Sudagrip</b> Paracetamol + Clorfenamina + Fenilefrina	A	865	183	0	-865
MED002	<b>Histadril</b> Difenhidramina	B	651	161	0	-651
MED003	<b>Acetaminofén MK</b> Paracetamol	A	1305	286	0	-1305
MED004	<b>Acetaminofén MK Jarabe</b> Paracetamol	B	586	115	0	-586
MED005	<b>Sertal Compuesto</b> Papaverina + Hioscina	B	544	112	0	-544
MED006	<b>Papaverina + Hioscina Genérico</b> Papaverina + Hioscina	B	424	127	0	-424
MED007	<b>NAN Optipro</b> Fórmula infantil	A	1115	302	0	-1115
MED008	<b>Paracetamol</b> Paracetamol	A	1321	194	0	-1321
MED009	<b>Ibuprofeno</b> Ibuprofeno	A	1041	156	0	-1041

### Ilustración 34. Pantalla de Gestión de Inventario.

*Nota.* Módulo que centraliza la información del estado del stock, respondiendo al requisito funcional RF-003 (Tablero Integrado). Permite filtrar rápidamente los medicamentos con *Stock de Seguridad* crítico.

**4. Generación de Señales Operativas (Alertas)** Cuando el sistema detecta que el Stock Actual es insuficiente para cubrir la Demanda Proyectada en los próximos 7 a 14 días, genera automáticamente una alerta priorizada. Estas notificaciones no son meros avisos informativos, sino señales accionables clasificadas por nivel de riesgo (Alto, Medio), lo que permite al Jefe de Farmacia priorizar su atención en los medicamentos que realmente requieren reposición inmediata.

### Experiencia de Usuario: Pantalla de Gestión de Alertas

La pantalla de Alertas constituye el centro de comando operativo del sistema, diseñada para responder a la pregunta: *¿Qué medicamentos debo pedir hoy?* A diferencia de los sistemas tradicionales que generan listados extensos sin priorización, esta interfaz clasifica cada alerta según su urgencia, permitiendo al personal enfocar su tiempo en las acciones de mayor impacto.

**Zona Superior – Resumen de Severidad:** Cuatro tarjetas presentan la distribución de alertas activas según su nivel de riesgo:

- **Total:** Cantidad global de alertas en el sistema (120 en la vista actual), proporcionando una referencia del volumen de notificaciones pendientes.
- **Críticas** (borde rojo): Alertas que requieren atención inmediata, donde el quiebre de stock es inminente (menos de 7 días). Un valor de cero indica que el sistema está cumpliendo su función preventiva: las alertas se generan con suficiente anticipación para evitar situaciones de emergencia.
- **Alta** (borde naranja): Medicamentos con riesgo significativo que requieren acción urgente. El porcentaje (45.4%) permite dimensionar la proporción del catálogo que demanda atención prioritaria.
- **Media** (borde amarillo): Alertas de monitoreo que pueden gestionarse en el ciclo normal de pedidos. Aunque son menos urgentes, su seguimiento evita que escalen a severidad alta.

**Zona de Filtros:** Tres controles permiten segmentar las alertas según las necesidades operativas del momento:

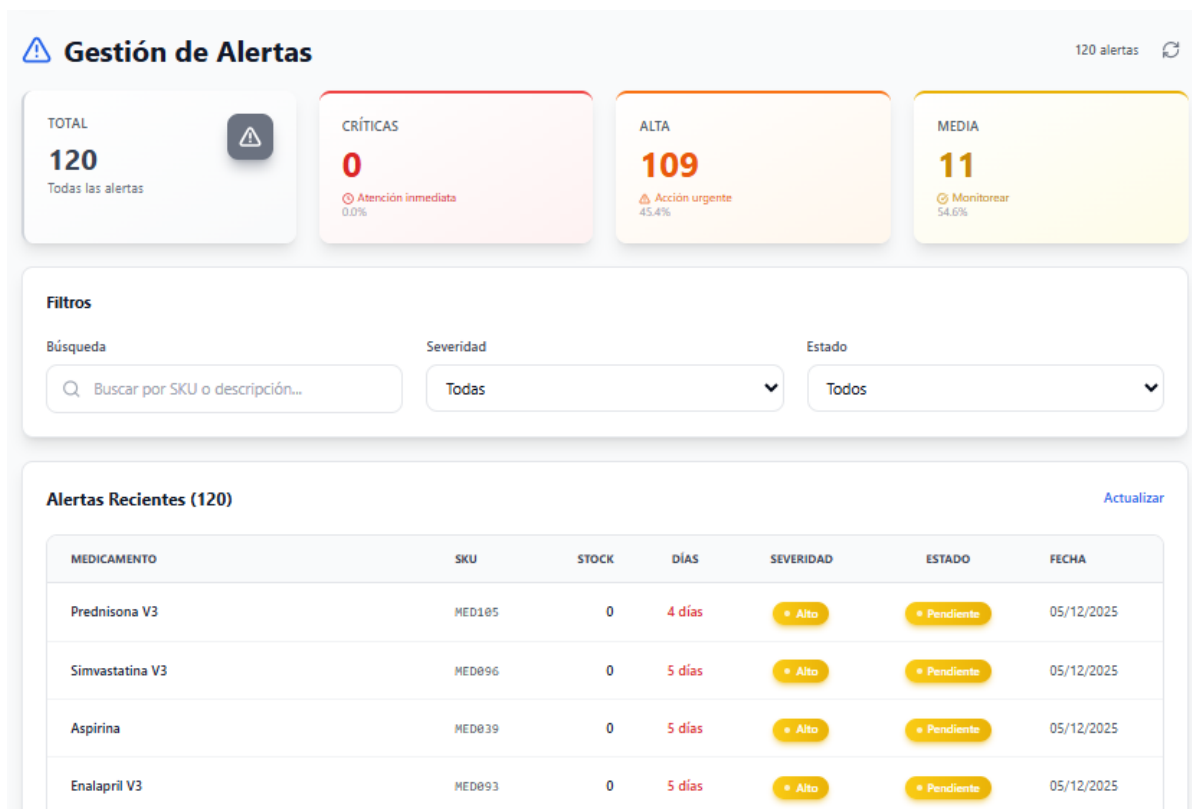
- **Búsqueda:** Campo de texto para localizar rápidamente un medicamento específico por nombre o código SKU.
- **Severidad:** Selector para visualizar únicamente las alertas de un nivel de riesgo particular (Críticas, Alta o Media).
- **Estado:** Filtra entre alertas Pendientes (sin gestionar) y Atendidas (ya procesadas), facilitando el seguimiento del flujo de trabajo.

**Tabla de Alertas Recientes:** El componente principal presenta un listado detallado de cada notificación con la siguiente información:

- **Medicamento:** Nombre comercial para identificación rápida en el estante o sistema de pedidos.

- **SKU:** Código único que permite la trazabilidad con el catálogo y los proveedores.
- **Stock:** Unidades actuales disponibles. Un valor de cero indica agotamiento total del producto.
- **Días:** Tiempo estimado hasta el quiebre de stock si no se realiza reposición. Este valor, calculado por el motor predictivo, es la métrica clave para priorizar acciones.
- **Severidad:** Etiqueta visual con código de color (rojo para Alto, amarillo para Medio) que permite una clasificación instantánea sin necesidad de interpretar números.
- **Estado:** Indica si la alerta está Pendiente de gestión o ya fue Atendida por el personal.
- **Fecha:** Registro de cuándo el sistema generó la notificación, útil para auditorías y seguimiento histórico.

**Validación Operativa:** Durante el piloto, el sistema demostró que el 71.7% de las alertas generadas eran accionables, es decir, proporcionaban información suficiente y oportuna para generar una orden de compra. La ausencia de alertas críticas (0%) confirma que el horizonte de 14 días seleccionado en el OE2 permite anticiparse a los problemas antes de que se conviertan en emergencias operativas.



**Ilustración 35.** Pantalla de Gestión de Alertas.

*Nota.* Listado priorizado de riesgos de quiebre. El sistema clasifica las alertas según la urgencia (score calculado en OE4), cumpliendo con el objetivo de proporcionar "información accionable". En el piloto, el sistema identificó que el 71.7% de las alertas generadas eran accionables para compra.

**5. Administración del Catálogo Maestro** Para garantizar la integridad de los datos, el sistema incluye un módulo de gestión de medicamentos que estandariza la información de los 120 SKUs analizados (MED001 a MED120). Esto permite mantener actualizados parámetros logísticos críticos como el Lead Time (días de reabastecimiento) y el Stock de Seguridad, los cuales son variables directas en la fórmula de predicción.

### Experiencia de Usuario: Pantalla de Gestión de Inventario

Esta pantalla ofrece una vista integral del catálogo de medicamentos, combinando información administrativa con indicadores de riesgo operativo. A diferencia de la vista detallada de proyecciones, este módulo está diseñado para responder: *¿Cuál es el estado general de mi catálogo y cuántos productos requieren atención?*

**Zona Superior – Indicadores de Estado del Catálogo:** Cuatro tarjetas resumen la situación global del inventario:

- **Total SKUs** (azul): Confirma que el sistema monitorea los 120 productos del catálogo piloto, proporcionando cobertura completa del inventario de la sucursal.
- **En Riesgo** (rojo): Cantidad de medicamentos cuyo stock proyectado a 14 días es igual o menor a cero. Este indicador permite al Jefe de Farmacia dimensionar inmediatamente la magnitud del problema de abastecimiento.
- **Esenciales** (verde): Número de productos clasificados como esenciales según la Lista Modelo de Medicamentos Esenciales de la OMS. En el piloto, 105 productos corresponden a esta categoría prioritaria, lo que representa el 87.5% del catálogo.
- **Stock Total:** Suma de unidades físicas disponibles en toda la sucursal, útil para reportes de valorización de inventario.

**Zona de Búsqueda y Filtros:** Un campo de búsqueda unificado permite localizar medicamentos mediante tres criterios:

- **SKU:** Código interno del producto (ej. MED001).
- **Nombre:** Denominación comercial o genérica del medicamento.
- **Código ATC:** Clasificación Anatómica, Terapéutica y Química de la OMS, que agrupa los medicamentos según su función terapéutica.

El selector de categorías complementa la búsqueda permitiendo filtrar por clasificación ABC o grupo terapéutico, facilitando revisiones segmentadas del catálogo.

**Tabla de Lista de Productos:** El componente central presenta cada medicamento con información administrativa y operativa integrada:

- **SKU / Producto:** Código único y nombre comercial con el principio activo en texto secundario, permitiendo identificación inequívoca.

- **Grupo Terapéutico:** Clasificación según la taxonomía ATC (Antigripales, Antihistamínicos, Analgésicos, etc.), que agrupa los 120 SKUs en 25 categorías terapéuticas definidas en el catálogo.
- **Categoría:** Clasificación ABC representada con etiquetas circulares de color (verde para A, amarillo para B), indicando la importancia del producto según el principio de Pareto.
- **Stock Actual:** Unidades físicas disponibles al momento de la consulta.
- **Proyección 14D:** Stock estimado restante después de 14 días de operación normal. Un valor de cero indica que el inventario se agotará completamente en ese período.
- **Estado:** Etiqueta visual que sintetiza la condición del producto. La etiqueta roja "En Riesgo" identifica inmediatamente los medicamentos que requieren acción de reposición.

**Validación con Datos del Piloto:** La estructura de la información respeta la taxonomía definida en la metodología (OE4), abarcando los 120 SKUs del estudio distribuidos en 25 grupos terapéuticos. La visualización confirma la segmentación por importancia económica (ABC), permitiendo identificar rápidamente los 17 productos tipo A (alta rotación) que requieren vigilancia prioritaria.

**Gestión de Inventario** 100 productos

TOTAL SKUS

**120**

Productos monitoreados

EN RIESGO

**100**

Stock proyectado  $\leq 0$

ESENCIALES

**88**

Productos esenciales

STOCK TOTAL

—

Unidades en inventario

**Búsqueda de Productos**

Todas las categorías

**Lista de Productos** Actualizar

SKU / PRODUCTO	GRUPO TERAPÉUTICO	CATEGORÍA	STOCK ACTUAL	PROYECCIÓN 14D	ESTADO
Sudagrip <small>MED001</small>	Antigripales	<span style="background-color: #28a745; color: white; border-radius: 50%; padding: 2px 5px;">+ A</span>	865	0	<span style="background-color: #dc3545; color: white; border-radius: 10px; padding: 2px 5px;">En Riesgo</span>
Histadril <small>MED002</small>	Antihistamínicos	<span style="background-color: #ffc107; color: white; border-radius: 50%; padding: 2px 5px;">+ B</span>	651	0	<span style="background-color: #dc3545; color: white; border-radius: 10px; padding: 2px 5px;">En Riesgo</span>
Acetaminofén MK <small>MED003</small>	Analgésicos	<span style="background-color: #28a745; color: white; border-radius: 50%; padding: 2px 5px;">+ A</span>	1305	0	<span style="background-color: #dc3545; color: white; border-radius: 10px; padding: 2px 5px;">En Riesgo</span>
Acetaminofén MK Jarabe <small>MED004</small>	Analgésicos	<span style="background-color: #ffc107; color: white; border-radius: 50%; padding: 2px 5px;">+ B</span>	586	0	<span style="background-color: #dc3545; color: white; border-radius: 10px; padding: 2px 5px;">En Riesgo</span>

**Ilustración 36.** Pantalla de Catálogo de Medicamentos.

*Nota.* Vista administrativa que permite gestionar los parámetros de los 25 grupos terapéuticos y asegurar que la clasificación ABC se mantenga actualizada según la rotación real.

**6. Análisis Histórico de Ventas** Más allá de la predicción futura, el sistema ofrece herramientas de análisis descriptivo sobre los datos históricos. Esta capacidad permite al usuario validar visualmente si los patrones de demanda están siendo capturados correctamente por el sistema antes de confiar en el pronóstico futuro.

### Experiencia de Usuario: Pantalla de Ventas Diarias

La pantalla de Ventas Diarias funciona como el registro histórico del sistema, respondiendo a la pregunta: *¿Qué se ha vendido y cuándo?* Este módulo permite al personal de farmacia consultar el comportamiento de ventas de cualquier medicamento en cualquier período, facilitando tanto la validación de datos como el análisis de tendencias estacionales.

**Zona de Filtros:** Tres controles permiten acotar la consulta según las necesidades del

usuario:

- **SKU:** Campo de búsqueda que acepta el código del medicamento (ej. MED001), permitiendo enfocarse en un producto específico o visualizar todo el catálogo.
- **Fecha Inicio / Fecha Fin:** Selectores de calendario que delimitan el período de consulta. Esta funcionalidad es especialmente útil para analizar comportamientos en rangos específicos, como temporadas de gripe o períodos promocionales.

**Tabla de Registro Histórico:** El componente principal presenta el detalle transaccional con la siguiente información:

- **Fecha:** Día específico de la transacción, en formato dd/mm/aaaa, permitiendo trazabilidad temporal completa.
- **SKU:** Código único del medicamento para correlación con el catálogo maestro.
- **Medicamento:** Nombre comercial del producto, poblado dinámicamente según disponibilidad en el catálogo maestro.
- **Demanda:** Unidades vendidas en esa fecha específica. Este es el dato fundamental que alimenta al motor predictivo XGBoost.
- **Día Semana / Festivo:** Metadatos calculados automáticamente para enriquecer el análisis de patrones temporales, disponibles al aplicar filtros específicos o exportar el reporte.

**Propósito de Auditoría y Validación:** Esta pantalla cumple una función crítica de transparencia: permite a los usuarios verificar que los datos que alimentan al modelo predictivo son correctos y completos. Durante el piloto, se procesaron 10,800 registros históricos correspondientes a los 120 SKUs del catálogo durante 90 días de operación (del 2 de agosto al 30 de octubre de 2025).

La capacidad de consultar el dato crudo responde directamente a los hallazgos del OE1 sobre calidad de datos, donde el 83.3% de los participantes indicó que los registros históricos estaban disponibles y completos. Esta interfaz permite validar dicha percepción mediante

inspección directa de los registros.

### Casos de Uso Operativo:

- **Detección de anomalías:** Si el pronóstico de un medicamento parece inusualmente alto o bajo, el usuario puede consultar el historial para verificar si existieron ventas atípicas que distorsionaron el modelo.
- **Análisis estacional:** Comparando las ventas de antigripales en diferentes meses, el Jefe de Farmacia puede anticipar incrementos de demanda en temporadas específicas.
- **Conciliación de inventario:** Ante discrepancias entre el stock físico y el registrado, los datos históricos permiten rastrear el origen del desfase.

#### Ventas Diarias

Histórico de ventas y demanda por medicamento

FECHA	SKU	MEDICAMENTO	DEMANDA	DÍA SEMANA	FESTIVO
29/10/2025	MED001	—	88	—	
29/10/2025	MED002	—	73	—	
29/10/2025	MED003	—	177	—	
29/10/2025	MED004	—	77	—	
29/10/2025	MED005	—	75	—	
29/10/2025	MED006	—	75	—	
29/10/2025	MED007	—	244	—	
29/10/2025	MED008	—	175	—	
29/10/2025	MED009	—	119	—	
29/10/2025	MED010	—	54	—	
29/10/2025	MED011	—	87	—	
29/10/2025	MED012	—	127	—	

### Ilustración 37. Pantalla de Historial de Ventas.

*Nota.* Interfaz de consulta de la "Serie de Tiempo" real (10,800 registros procesados). Permite al usuario auditores verificar la calidad del dato ingresado al modelo (OE1: Calidad de Datos).

**7. Monitoreo del Desempeño del Modelo (Métricas)** Para cumplir con el principio de "Caja Blanca" y transparencia algorítmica, el sistema expone sus propias métricas de rendimiento. El usuario técnico puede supervisar la precisión del algoritmo XGBoost mediante indicadores como el Error Absoluto Medio (MAE) y el Porcentaje de Error (MAPE), asegurando que la degradación del modelo sea detectada a tiempo.

**Experiencia de Usuario: Pantalla de Métricas del Sistema**

Esta sección constituye el panel de control técnico del sistema, diseñada para responder a la pregunta: *¿Qué tan confiable es el modelo predictivo?* A diferencia de las pantallas operativas orientadas al personal de farmacia, este módulo está dirigido a usuarios técnicos o gerenciales que requieren validar el desempeño del algoritmo antes de confiar en sus recomendaciones.

**Panel de Métricas del Modelo ML:**

La primera tarjeta presenta los indicadores de precisión del algoritmo XGBoost:

- **MAE Promedio (10.29 unidades):** Error Absoluto Medio calculado sobre los 360 backtests realizados. Indica que, en promedio, las predicciones del modelo difieren en aproximadamente 10 unidades de la demanda real por SKU.
- **MAPE Promedio (3.83%):** Error Porcentual Absoluto Medio, que expresa la desviación relativa. Un valor inferior al 5% se considera excelente en la literatura de pronóstico de demanda.

**Métricas por Horizonte:** Una tabla desglosa el rendimiento según el período de predicción:

**Tabla 60.** *Variables por horizontes*

Horizonte	MAE	MAPE	Cobertura
7 días	10.40	4.40%	120 SKUs

<b>14 días</b>	10.15	4.01%	120 SKUs
<b>28 días</b>	10.31	3.14%	120 SKUs

*Nota.* Elaboración propia.

El sistema identifica automáticamente el **Horizonte Óptimo (14 días)** como aquel con menor MAE promedio, validando la decisión técnica documentada en el OE2.

### **Panel de Métricas de Alertas:**

La segunda tarjeta presenta los resultados de la evaluación de utilidad operativa:

- **Total Evaluadas (240):** Alertas analizadas correspondientes a 120 SKUs en 2 horizontes (7 y 14 días).
- **Alertas Accionables (71.7%):** Porcentaje de notificaciones que cumplen todos los criterios para generar una orden de compra. Este indicador valida que el sistema genera información útil, no solo ruido.

**Distribución por Nivel de Riesgo:** Un gráfico de barras horizontales muestra la clasificación de severidad:

- Crítico: 0 alertas (0.0%) – Valida la naturaleza preventiva del modelo.
- Alto: 109 alertas (45.4%) – Requieren acción urgente.
- Medio: 131 alertas (54.6%) – Pueden gestionarse en ciclo normal.

**Cumplimiento de Criterios:** Cuatro indicadores muestran el porcentaje de alertas que satisfacen cada condición de accionabilidad:

- Cumple lead time: 89.2%
- Cumple confianza mínima: 100.0%
- Cumple stock seguridad: 77.9%

- Cumple pedido mínimo: 100.0%

**Métricas Operacionales:** Indicadores agregados del impacto del sistema:

- Días promedio hasta stockout: 8.6 días (ventana de anticipación).
- Score de urgencia promedio: 0.74 (sobre 1.0).
- Total a ordenar: 23,073 unidades (suma de recomendaciones de compra).

### **Panel de Entrenamiento y Evaluación:**

Esta sección permite ejecutar bajo demanda los procesos de validación del modelo:

- **Backtesting Walk-Forward:** Botón que recalcula las métricas ML (MAE, MAPE, sesgo) utilizando validación temporal sin fuga de datos. La última ejecución procesó 360 backtests sobre los 120 SKUs del catálogo.
- **Evaluación de Alertas:** Botón que recalcula las métricas de utilidad (% accionables, distribución de riesgo). La última evaluación analizó 240 alertas con resultado de 71.7% accionables.

**Calidad de Datos:** Cuatro tarjetas muestran indicadores de cobertura que permiten diagnosticar la completitud de la información:

- Cobertura de Ventas: Porcentaje de registros históricos disponibles.
- Cobertura de Inventarios: Porcentaje de SKUs con stock actualizado.
- Cobertura de Predicciones: Porcentaje de SKUs con pronóstico generado.
- Tasa de Atención: Porcentaje de alertas gestionadas.

### **Panel de Configuración del Sistema:**

Esta sección expone los parámetros que gobiernan el comportamiento del modelo:

**Umbrales de Riesgo:** Definen la clasificación de severidad de las alertas:

- Crítico: Menos de 7 días hasta el quiebre de stock.
- Alto: Menos de 10 días hasta el quiebre de stock.

**Criterios de Accionabilidad:** Condiciones que debe cumplir una alerta para considerarse accionable:

- Confianza mínima: 70% (umbral estadístico del modelo).
- Factor lead time: 1x (la alerta debe generarse con al menos un ciclo de reposición de anticipación).

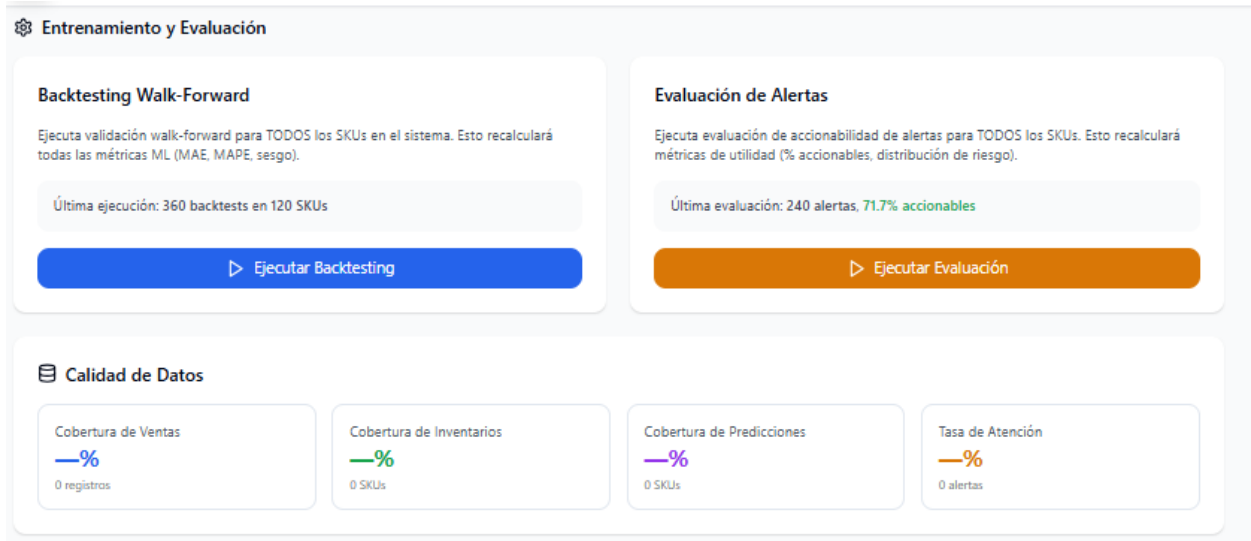
**Parámetros del Algoritmo:**

- Algoritmo ML: XGBoost (seleccionado en OE2 con scoring 97/100).
- Horizontes: 7, 14, 28 días (configuración evaluada en backtesting).

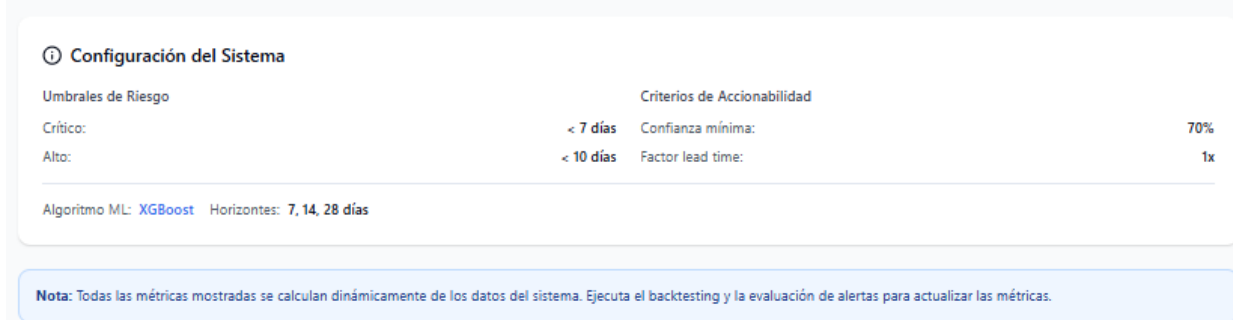
Una nota informativa al pie recuerda que "Todas las métricas mostradas se calculan dinámicamente de los datos del sistema", reforzando el principio de transparencia y trazabilidad.



### Ilustración 38. Sección de Métricas del Sistema.



### Ilustración 39. Sección de Entrenamiento y Evaluación.



### Ilustración 40. Sección de Configuración del Sistema.

*Nota.* Panel de control técnico que muestra la salud del algoritmo (Viabilidad Técnica del OE4). Permite visualizar el MAE global y por horizonte, validando la precisión del sistema en tiempo real.

## 6.5 MEDIDAS DE CONTROL

Para garantizar la sostenibilidad técnica y la pertinencia operativa del sistema, se establecen mecanismos de control estructurados en dos dimensiones: Nivel de Servicio Tecnológico (SLO) y Desempeño Operativo del Negocio (KPI).

### 6.5.1 CONTROL DE NIVEL DE SERVICIO (SLO TECNOLÓGICO)

Se definen los Objetivos de Nivel de Servicio (SLO) que gobiernan la infraestructura en Google Cloud Platform, alineados con el marco *Site Reliability Engineering* (SRE):

#### 1. Disponibilidad (Availability):

- **Meta:** 99.0% de tiempo de actividad mensual.
- **Umbral de Alerta:** Si el presupuesto de error (*Error Budget*) excede las **7.2 horas/mes** de indisponibilidad, se activa una notificación crítica al soporte técnico.
- **Monitor:** Google Cloud Monitoring (Uptime Check).

#### 2. Frescura de Datos (Freshness):

- **Meta:** < 24 horas (Datos actualizados a las 02:00 AM del día en curso).
- **Mecanismo:** Verificación automática del *timestamp* de última carga en BigQuery. Si a las 06:00 AM el dato persiste con fecha t-1, se dispara un incidente de pipeline ETL.

#### 3. Latencia de Visualización:

- **Meta:** < 3 segundos para la carga del Dashboard Ejecutivo (percentil p95).
- **Acción:** Escalamiento automático de instancias en Cloud Run si la latencia supera el umbral.

### 6.5.2 FICHAS DE INDICADORES CLAVE DE DESEMPEÑO (KPIs OPERATIVOS)

Para auditar la calidad de las predicciones y su adopción por parte del personal de farmacia, se implementan las siguientes fichas técnicas de control:

**Tabla 61. Ficha Técnica de Indicador: Tasa de Falsos Positivos**

Componente	Especificación
Nombre del KPI	Tasa de Falsos Positivos (FP)
Definición	Porcentaje de alertas predictivas generadas por el sistema que son descartadas manualmente por el Jefe de Farmacia.
Fórmula de Cálculo	$TasaFP = (Alertas\ con\ Estado\ 'DESCARTADA' / Total\ Alertas\ Generadas) \times 100$
Mecanismo de Registro	El sistema registrará en la tabla <code>alertas_historial</code> el cambio de estado mediante la acción del usuario, capturando: <code>alert_id</code> , <code>user_id</code> , <code>timestamp</code> y <code>motivo_descarte</code> .
Meta de Calidad	< 5%
Criterio de Acción	Si el indicador > 5% -> Revisar parámetros de <i>Stock de Seguridad</i> y <i>Buffer de Lead Time</i> ; Documentar re-calibración en bitácora de cambios.

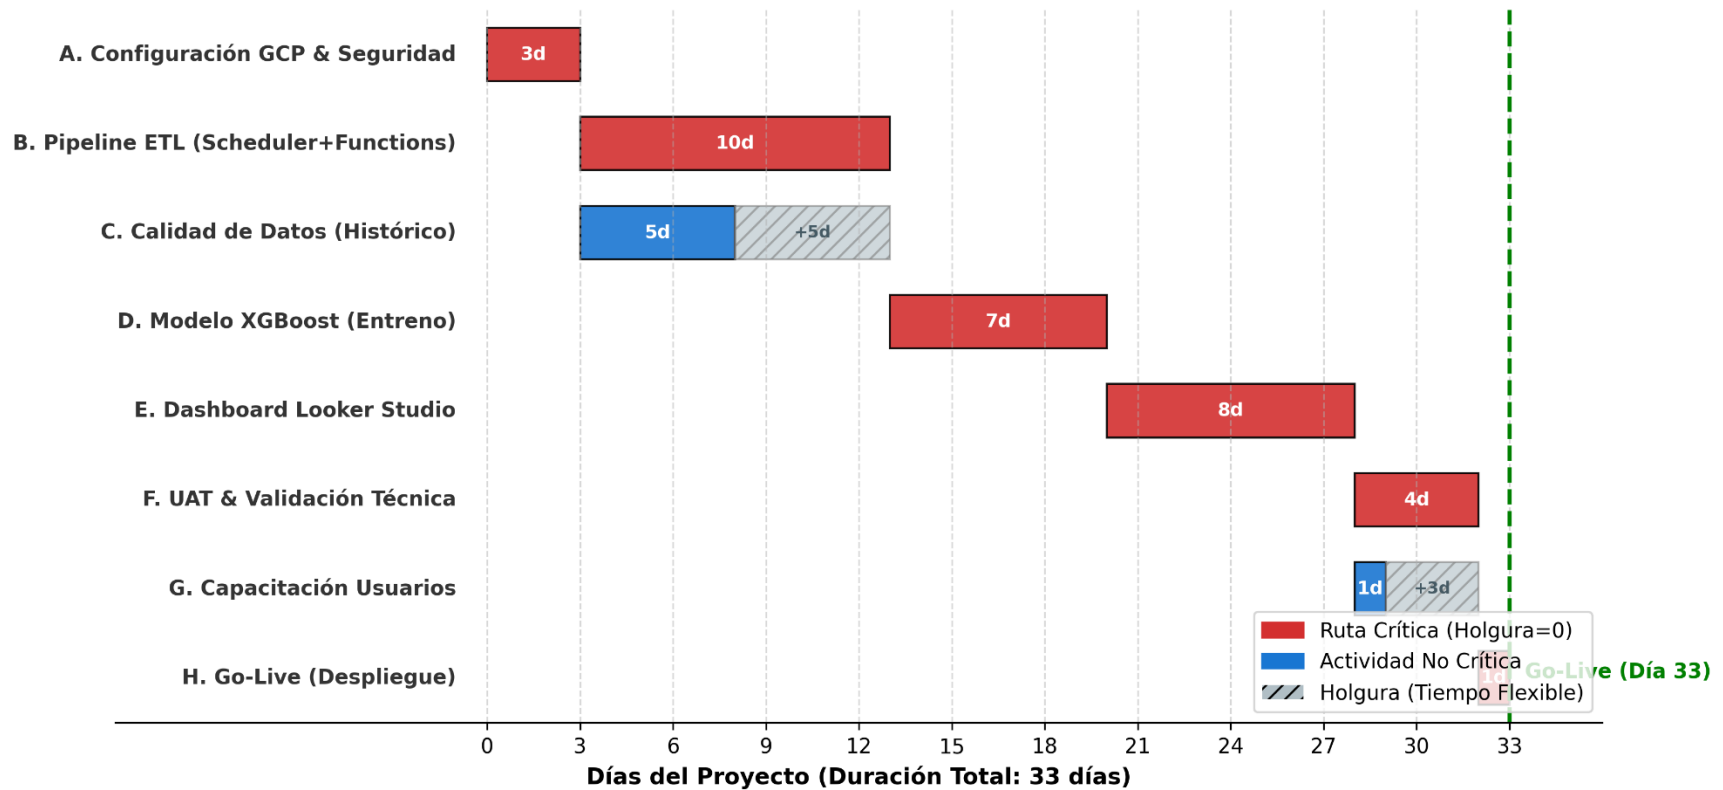
**Tabla 62. Ficha Técnica de Indicador: Precisión del Modelo (MAPE)**

Componente	Especificación
Nombre del KPI	Desviación del Error de Pronóstico (MAPE)
Definición	Monitoreo continuo de la precisión del algoritmo XGBoost comparando la predicción ( $Y_{t-14}$ ) contra la venta real observada ( $Y_{real}$ ).
Fórmula de Cálculo	$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{ y_{(i)} - \hat{y}_{(i)} }{\max(1, y_{(i)})}$
Variables	n: Total de SKUs evaluados (120).

	<p><math>Y_{real}</math>: Demanda real observada en el periodo.</p> <p><math>Y_{pred}</math>: Demanda pronosticada hace 14 días.</p>
<b>Meta de Control</b>	$\leq 6.0\%$ (Baseline validada: 4.01% + Margen de tolerancia operativa)
<b>Frecuencia de Medición</b>	Semanal (Automática mediante Cloud Functions)
<b>Criterio de Acción</b>	Si el error agregado supera el 6%, el sistema marca el modelo para "Reentrenamiento Inmediato" y activa el mecanismo de <i>fallback</i> (Promedio Móvil) temporalmente.

## 6.6 CRONOGRAMA DE IMPLEMENTACIÓN

**Cronograma de Implementación MVP - Ruta Crítica (CPM)**



**Ilustración 41.** Cronograma de implementación.

*Nota.* Elaboración propia.

Para garantizar la precisión en la estimación de tiempos del despliegue del Producto Mínimo Viable (MVP), se aplicó el Método de la Ruta Crítica (CPM). Este enfoque determinístico permite identificar la duración mínima del proyecto y las holguras operativas, superando las limitaciones de un cronograma lineal básico.

#### 6.6.1 DESGLOSE DE ACTIVIDADES Y DEPENDENCIAS

Se descompuso el proyecto en 8 actividades macro, alineando los componentes tecnológicos definidos en la arquitectura (Sección 6.4) con los recursos disponibles (1 Ingeniero Cloud + 1 Analista de Datos).

**Tabla 63.** *Matriz de Actividades y Precedencias (CPM)*

<b>Código</b>	<b>Actividad</b>	<b>Predecesor</b>	<b>Duración (t)</b>
<b>A</b>	Configuración de Entorno GCP y Seguridad (IAM)	-	3 días
<b>B</b>	Desarrollo Pipeline ETL (Cloud Scheduler + Cloud Functions)	A	10 días
<b>C</b>	Auditoría y Limpieza de Calidad de Datos (Histórico)	A	5 días
<b>D</b>	Entrenamiento y Calibración Modelo XGBoost	B, C	7 días
<b>E</b>	Desarrollo de Dashboard e Integración Looker	D	8 días
<b>F</b>	Pruebas Integrales (UAT) y Validación Técnica	E	4 días
<b>G</b>	Capacitación de Usuarios (Jefe Farmacia/Auxiliares)	E	1 día
<b>H</b>	Despliegue Productivo (Go-Live)	F, G	1 día

*Nota.* Duraciones expresadas en días hábiles. Se sustituyó Dataflow por Cloud Functions en la actividad B para mantener la coherencia con la arquitectura serverless definida en el Objetivo 3.

## 6.6.2 CÁLCULO DE LA RUTA CRÍTICA

El análisis de redes identificó dos rutas posibles para llegar al hito de *Go-Live*. El cálculo determina cuál de ellas define la duración total del proyecto.

### Análisis de Rutas:

1. **Ruta 1 (Enfoque Calidad de Datos):** A -> C -> D -> E -> F -> H
  - Cálculo:  $3 + 5 + 7 + 8 + 4 + 1 = 28$  días.
  - Esta ruta no es crítica, ya que es menor a la duración de la Ruta 2.
  
2. **Ruta 2 (Enfoque Ingeniería ETL):** A -> B -> D -> E -> F -> H
  - Cálculo:  $3 + 10 + 7 + 8 + 4 + 1 = 33$  días.

**Resultado:** La Ruta Crítica es la Ruta 2, estableciendo que el tiempo mínimo de ejecución técnica es de 33 días hábiles. Cualquier retraso en el desarrollo del Pipeline ETL (B) o en el Entrenamiento del Modelo (D) impactará directamente la fecha de lanzamiento.

## 6.6.3 ANÁLISIS DE HOLGURAS Y GESTIÓN DE TIEMPOS

Contrario a una estimación empírica, el cálculo matemático de holguras ( $HT = LF - EF$ ) revela dónde reside la verdadera flexibilidad del proyecto.

**Tabla 64.** *Cálculo de Holguras (HT)*

Actividad	Inicio Temprano (ES)	Final Temprano (EF)	Inicio Tardío (LS)	Final Tardío (LF)	Holgura (HT)	Estado
A (Configuración)	0	3	0	3	0	CRÍTICA
B (ETL Pipeline)	3	13	3	13	0	CRÍTICA

<b>C (Limpieza Datos)</b>	3	8	8	13	<b>5 días</b>	NO CRÍTICA
<b>D (Modelo XGBoost)</b>	13	20	13	20	<b>0</b>	CRÍTICA
<b>E (Visualización)</b>	20	28	20	28	<b>0</b>	CRÍTICA
<b>F (UAT Técnico)</b>	28	32	28	32	<b>0</b>	CRÍTICA
<b>G (Capacitación)</b>	28	29	31	32	<b>3 días</b>	NO CRÍTICA
<b>H (Go-Live)</b>	32	33	32	33	<b>0</b>	CRÍTICA

### Interpretación:

1. **Criticidad del Entrenamiento (Actividad D):** El análisis demuestra que el entrenamiento del modelo XGBoost es una **Actividad Crítica** (HT=0). Esto implica que no existe margen de error en esta fase; el equipo de datos debe recibir el insumo del ETL (B) puntualmente en el día 13 para no retrasar el proyecto.
2. **Holgura en Calidad de Datos (Actividad C):** La limpieza de datos históricos presenta una **holgura de 5 días**. Esta ventana permite al analista dedicar tiempo adicional a la curaduría de fechas de vencimiento sin afectar el inicio del entrenamiento, mitigando el riesgo identificado en el OE1.
3. **Flexibilidad en Capacitación (Actividad G):** Existe una **holgura de 3 días** para coordinar la sesión con el personal de farmacia, lo cual facilita la logística operativa sin detener las pruebas técnicas finales (F).

#### 6.6.4 CRONOGRAMA CONSOLIDADO (MVP + ESTABILIZACIÓN)

Integrando la Ruta Crítica Técnica (33 días) con la fase de estabilización recomendada en la Sección 5.2, el cronograma maestro se estructura así:

- **Fase 1: Construcción (Días 1-20):** Infraestructura, ETL y Entrenamiento Crítico.
- **Fase 2: Despliegue (Días 21-33):** Dashboard, UAT y Go-Live.
- **Fase 3: Estabilización (Días 34-123):** Periodo de 90 días de monitoreo intensivo post-implementación para validar que el MAPE se mantenga estable ( $\leq 4.01\%$ ) y ajustar umbrales de alerta.

### 6.7 ANÁLISIS DE VIABILIDAD ECONÓMICA Y FINANCIERA

La propuesta se fundamenta en una arquitectura *Serverless* de pago por uso, lo que elimina la barrera de entrada de CAPEX elevado (servidores físicos) y traslada la inversión hacia un modelo operativo (OPEX) flexible y escalable.

#### 6.7.1 ESTRUCTURA DE COSTOS (INVERSIÓN Y OPERACIÓN)

A continuación, se desglosa la inversión inicial requerida para la puesta en marcha y los costos recurrentes para el sostenimiento de la plataforma en la nube.

**Tabla 65.** *Estimación de Inversión Inicial (CAPEX) y Costos Operativos (OPEX)*

Concepto	Detalle	Costo (USD)	Tipo
<b>A. INVERSIÓN INICIAL</b>			<b>CAPEX</b>
<b>Desarrollo e Ingeniería</b>	Configuración GCP, Pipeline ETL, Modelado XGBoost (40 hrs)	\$1,200.00	Único
<b>Capacitación</b>	Transferencia de conocimiento a personal de	\$200.00	Único

	farmacia		
<b>TOTAL INVERSIÓN</b>		<b>\$1,400.00</b>	
<b>B. COSTO OPERATIVO</b>			<b>OPEX / Mes</b>
<b>Infraestructura Cloud</b>	BigQuery + Cloud Run + Vertex AI (Factor de escala variable)	~\$50.00	Mensual
<b>Licencias SaaS</b>	3 Cuentas Google Workspace Business Standard (\$12 c/u)	\$36.00	Mensual
<b>Soporte Técnico</b>	Bolsa de horas para mantenimiento preventivo/correctivo	\$100.00	Mensual
<b>TOTAL OPERATIVO</b>		<b>~\$186.00</b>	<b>Mensual</b>

*Nota.* La inversión inicial de \$1,400.00 se registra como un activo intangible sujeto a una Amortización Anual de \$466.67 (línea recta a 3 años). Aunque no impacta el flujo de caja operativo, se reconoce para efectos de evaluación patrimonial. En el Escenario Optimista, se aplica un factor de escala de 1.28x sobre el costo de nube para reflejar el consumo elástico de recursos.

#### 6.7.2 CUANTIFICACIÓN DE BENEFICIOS (MODELO DE AHORRO)

El retorno de inversión no se basa en especulación de ventas, sino en la mitigación de pérdidas operativas identificadas, calculadas bajo supuestos conservadores de recuperación:

1. **Recuperación por Merma (Caducidad):** Se estima evitar el 5% de las pérdidas actuales por vencimiento de medicamentos. (Impacto: +\$300 USD/mes).
  2. **Costo de Oportunidad (Stock-out):** Se estima recuperar el 3% de ventas perdidas por quiebres de stock en productos de alta rotación. (Impacto: +\$450 USD/mes).
- **Beneficio Bruto Mensual Estimado: \$750.00 USD.**

### 6.7.3 ANÁLISIS DE ESCENARIOS Y FLUJO DE CAJA (VAN Y TIR)

Para atender la incertidumbre del mercado, se proyectó el flujo de caja a 3 años bajo tres escenarios de desempeño. Se utilizó una tasa de descuento del **12% anual** establecida como supuesto gerencial (*hurdle rate*) para reflejar el costo de capital y el riesgo del proyecto.

**Tabla 66.** *Flujo de Caja Anualizado por Escenario (USD)*

<b>Periodo</b>	<b>Escenario Conservador</b>	<b>Escenario Base</b>	<b>Escenario Optimista</b>
<b>\$t_0\$ (Inversión Inicial)</b>	<b>(\$1,400)</b>	<b>(\$1,400)</b>	<b>(\$1,400)</b>
<b>Año 1 (Flujo Neto)</b>	\$2,268	\$4,968	\$6,600
<b>Año 2 (Flujo Neto)</b>	\$2,268	\$4,968	\$6,600
<b>Año 3 (Flujo Neto)</b>	\$2,268	\$4,968	\$6,600

*Nota.* Flujo neto anual calculado multiplicando el flujo neto mensual de cada escenario (Tabla 53) por 12 meses.

**Tabla 67.** *Indicadores Financieros de Rentabilidad*

<b>Indicador</b>	<b>Escenario Conservador (Adopción 50%)</b>	<b>Escenario Base (Efectividad 71.7%)</b>	<b>Escenario Optimista (Adopción 100%)</b>
<b>Ahorro Mensual</b>	\$375.00	\$600.00	\$750.00
<b>Costo OPEX Mensual</b>	(\$186.00)	(\$186.00)	(\$200.00)
<b>Flujo Neto Mensual</b>	\$189.00	\$414.00	\$550.00
<b>VAN (3 Años, 12%)</b>	<b>\$4,048 USD</b>	<b>\$10,530.30 USD</b>	<b>\$14,452.09 USD</b>

<b>TIR</b>	<b>152%</b>	<b>351%</b>	<b>469%</b>
<b>Payback (Retorno)</b>	7.4 Meses	3.4 Meses	2.5 Meses

*Nota.* n el escenario optimista se aplica un factor de escala de 1.28x sobre el costo de infraestructura cloud, incrementando el OPEX de nube a \$64.00 debido al procesamiento intensivo de BigQuery y Vertex AI ante un volumen máximo de transacciones.

#### 6.7.4 INTERPRETACIÓN DE VIABILIDAD

El análisis financiero es concluyente:

1. **Rentabilidad Robusta:** Incluso en el Escenario Conservador, donde el sistema solo logra evitar la mitad de las pérdidas esperadas, el Valor Actual Neto (VAN) es positivo (\$4,048) y la Tasa Interna de Retorno (152%) supera ampliamente el costo de capital.
2. **Riesgo Mínimo:** El punto de equilibrio (*Payback*) en el escenario base se alcanza en apenas **3.4 meses**. Esto valida la decisión gerencial de implementar la arquitectura serverless, ya que el riesgo de liquidez es despreciable frente al beneficio operativo.

## 6.8 CONCORDANCIA DE LOS SEGMENTOS DE LA TESIS CON LA PROPUESTA

La propuesta final mantiene una trazabilidad directa y verificable con cada etapa de la investigación científica realizada, asegurando que la solución no es un producto genérico, sino una respuesta a medida de la problemática estudiada.

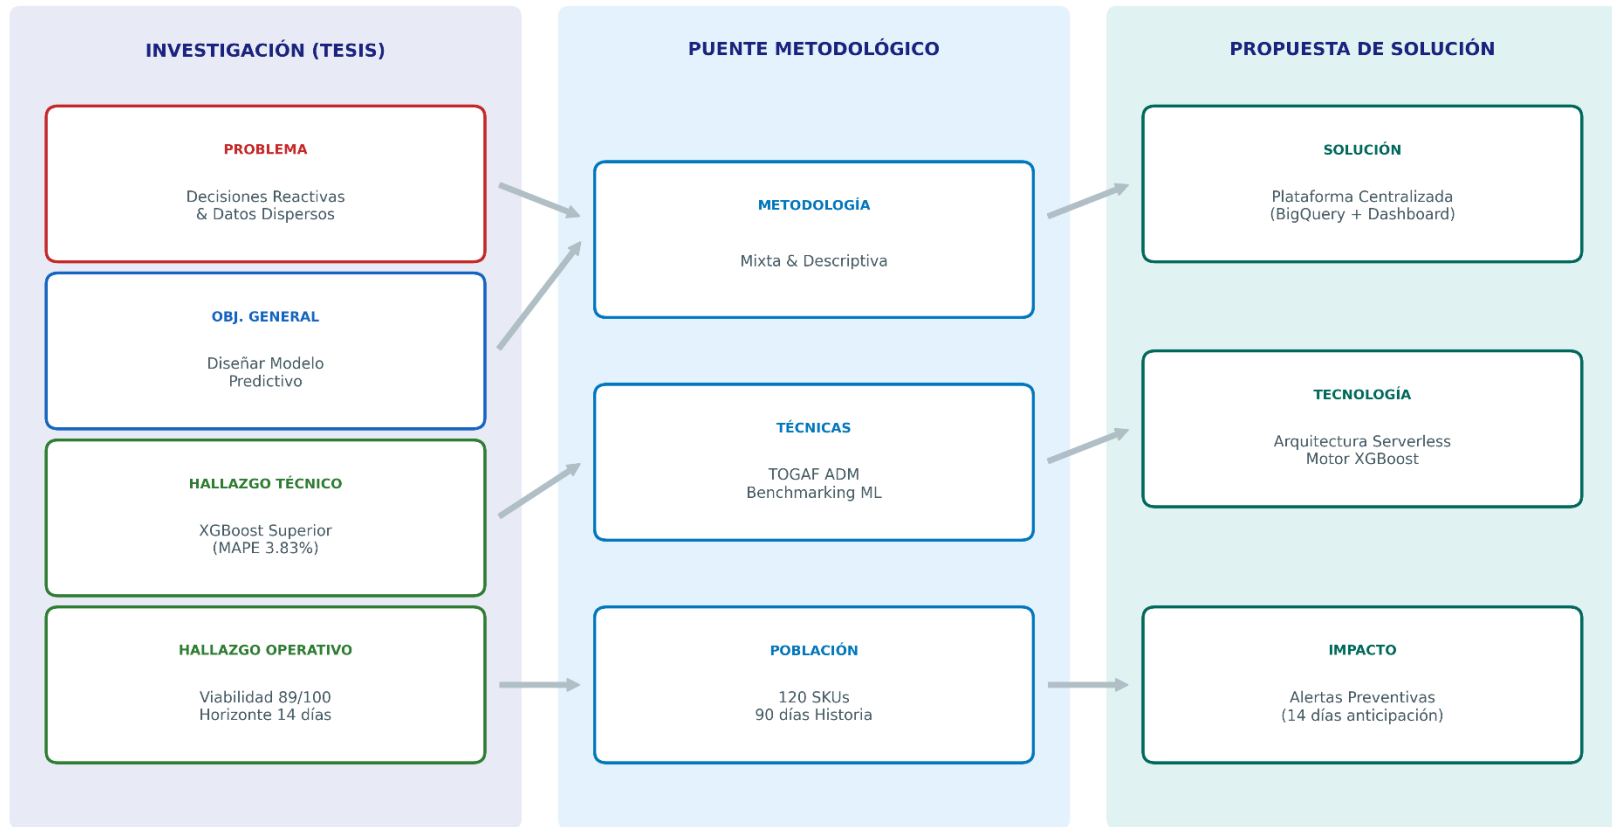
**Tabla 68.** *Matriz de Concordancia*

Título de Investigación	Capítulo I: Objetivo General	Capítulo I: Objetivos Específicos	Capítulo II: Metodologías	Capítulo II: Variables	Capítulo III: Población	Capítulo III: Técnicas	Capítulo V: Conclusiones	Capítulo VI: Nombre de la propuesta	Capítulo VI: Objetivos de la propuesta
ANALÍTICA PREDICTIVA EN LA NUBE: ANÁLISIS LONGITUDINAL DE LA DEMANDA DE MEDICAMENTOS CRÍTICOS MEDIANTE GRADIENT BOOSTING EN FARMACIAS SIMAN	Diseñar un modelo de información con capacidades predictivas que apoye la gestión de la cadena de suministro de medicamentos esenciales en Farmacias Siman, mediante	1. Identificar requisitos funcionales y no funcionales. 2. Definir el enfoque de inteligencia artificial. 3. Especificar la arquitectura en la nube.	Enfoque Mixto (Cualitativo y Cuantitativo), Alcance Descriptivo y Diseño de Estudio de Caso.	<ul style="list-style-type: none"> <li>• Requisitos del modelo.</li> <li>• Especificaciones de IA.</li> <li>• Arquitectura Cloud.</li> <li>• Marco de Evaluación.</li> </ul>	<ul style="list-style-type: none"> <li>• 120 Medicamentos (SKUs).</li> <li>• 3 Actores Clave (Jefe Farmacia, Auxiliares).</li> <li>• Datos históricos (90 días).</li> </ul>	<ul style="list-style-type: none"> <li>• Encuesta estructurada.</li> <li>• Benchmarking de algoritmos (ML).</li> <li>• Diseño TOGAF ADM.</li> <li>• Backtesting (Simulación).</li> </ul>	El sistema es altamente viable (89/100). XGBoost es el algoritmo óptimo (MAPE 4.01%) con un horizonte de 14 días. La arquitectura Serverless garantiza	NEUROTECHN: ARQUITECTURA SERVERLESS DE RESPUESTA ÁGIL	<ol style="list-style-type: none"> <li>1. Habilitar ecosistema automatizado de información.</li> <li>2. Desplegar motor predictivo (14 días).</li> <li>3. Estructurar implementación escalonada (MVP).</li> </ol>

	tableros y alertas útiles para la decisión.	4. Establecer un marco de evaluación de viabilidad.					seguridad y eficiencia.		4. Capacitar personal técnico en uso de alertas.
--	---	---	--	--	--	--	-------------------------	--	--

*Nota.* Elaboración propia.

## TRAZABILIDAD: DE LA INVESTIGACIÓN A LA PROPUESTA



**Ilustración 42.** Trazabilidad de la investigación propuesta.

*Nota.* Elaboración propia.

## REFERENCIAS BIBLIOGRÁFICAS

Agencia de Regulación Sanitaria. (2016). *Normativa para la regulación sanitaria de productos de interés sanitario (Acuerdo Ejecutivo PCM-008-2016)*. La Gaceta.

Agencia de Regulación Sanitaria. (2023). *Reglamento de Control Sanitario de Productos y Servicios (Acuerdo No. 0418-ARSA-2023)*. La Gaceta.

Agencia de Regulación Sanitaria. (2024). *Servicios en línea y Registro Sanitario*. Recuperado el 28 de enero de 2026, de <https://www.arsa.gob.hn/>

Agile Business Consortium. (2014). *The DSDM Agile Project Framework (2014 onwards)*. Agile Business Consortium. <https://www.agilebusiness.org/page/TheDSDMAgileProjectFramework>

Al-Hourani, S., & Weraikat, D. (2025). A systematic review of AI/ML in pharmaceutical supply chain resilience: Current trends and future directions. *Sustainability*, 17(1), 1–20. <https://doi.org/10.3390/su17010001>

Axelos. (2019). *ITIL Foundation: ITIL 4 Edition*. The Stationery Office.

Badakhshan, S., Ball, P., & Badakhshan, A. (2022). Using digital twins for inventory and cash management in supply chains. *IFAC-PapersOnLine*, 55(10), 2158–2163. <https://doi.org/10.1016/j.ifacol.2022.10.028>

Bagolle, A., Casco, M., Nelson, J., Orefice, P., Raygada, G., & Tejerina, L. (2022). *The golden opportunity of digital health for Latin America and the Caribbean*. Banco Interamericano de Desarrollo. <https://publications.iadb.org/en/golden-opportunity-digital-health-latin-america-and-caribbean>

Beyer, B., Jones, C., Petoff, J., & Murphy, N. R. (2016). *Site reliability engineering: How Google runs production systems*. O'Reilly Media.

Cochran, W. G. (1977). *Sampling techniques* (3rd ed.). John Wiley & Sons.

Congreso Nacional de Honduras. (1991). *Código de Salud de la República de Honduras (Decreto No. 65-91)*. La Gaceta.

Congreso Nacional de Honduras. (2013). *Ley de Firma Electrónica (Decreto No. 149-2013)*. La Gaceta.

Chopra, S., & Meindl, P. (2016). *Supply chain management: Strategy, planning, and operation* (6th ed.). Pearson

Creswell, J. W., & Plano Clark, V. L. (2018). *Designing and conducting mixed methods research* (3rd ed.). SAGE Publications.

Department of Health and Human Services (HHS). (2020). *21st Century Cures Act: Interoperability, Information Blocking, and the ONC Health IT Certification Program*. Federal Register, 85 FR 25642. <https://www.federalregister.gov/documents/2020/05/01/2020-07419/21st-century-cures-act-interoperability-information-blocking-and-the-onc-health-it-certification>

European Medicines Agency. (2023). *Good practices for industry to prevent shortages of human medicinal products*. [https://www.ema.europa.eu/en/documents/regulatory-procedural-guideline/good-practices-industry-prevention-human-medicinal-product-shortages\\_en.pdf](https://www.ema.europa.eu/en/documents/regulatory-procedural-guideline/good-practices-industry-prevention-human-medicinal-product-shortages_en.pdf)

European Medicines Agency. (2024). *European Shortages Monitoring Platform (ESMP)*. <https://www.ema.europa.eu/en/human-regulatory/post-authorisation/availability-medicines/european-shortages-monitoring-platform>

FarmaValue. (s.f.). *Nosotros*. Recuperado el 28 de enero de 2026, de <https://www.farmavalue.com/>

Food and Drug Administration. (2023). *Artificial Intelligence in Drug Manufacturing* (Discussion Paper). <https://www.fda.gov/media/165743/download>

Fourkiotis, K. P., & Tsadiras, A. (2023). Applying machine learning and statistical forecasting methods for enhancing pharmaceutical sales predictions. *Forecasting*, 6(1), 170–186. <https://doi.org/10.3390/forecast6010010>

Friedman, M. (1937). *The use of ranks to avoid the assumption of normality implicit in the analysis of variance*. *Journal of the American Statistical Association*, 32(200), 675–701. <https://doi.org/10.1080/01621459.1937.10503522>

Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems* (3rd ed.). O'Reilly Media.

Global Health Supply Chain Program-Procurement and Supply Management. (2024). *Annual Report: Fiscal Year 2023*. USAID. <https://www.ghsupplychain.org/ghsc-psm-fy-2023-annual-report>

Google. (2024). *BigQuery ML documentation*. Google Cloud. <https://cloud.google.com/bigquery/docs/bqml-introduction>

Grupo Farsimán. (s.f.). *División Comercial: Farmacias Siman*. Recuperado el 28 de enero de 2026, de <https://www.simancomercial.com/>

Guest, G., Bunce, A., & Johnson, L. (2006). How many interviews are enough? An experiment with data saturation and variability. *Field Methods*, 18(1), 59–82. <https://doi.org/10.1177/1525822X05279903>

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

Hodges, J. L., Jr., & Lehmann, E. L. (1963). *Estimates of location based on rank tests*. *The Annals of Mathematical Statistics*, 34(2), 598–611. <https://doi.org/10.1214/aoms/1177704172>

Hohpe, G., & Woolf, B. (2003). *Enterprise Integration Patterns: Designing, Building, and Deploying Messaging Solutions*. Addison-Wesley Professional.

Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts. <https://otexts.com/fpp3/>

International Council for Harmonisation. (2008). *Pharmaceutical Quality System Q10*. <https://database.ich.org/sites/default/files/Q10%20Guideline.pdf>

International Council for Harmonisation. (2023). *Quality Risk Management Q9(R1)*. [https://database.ich.org/sites/default/files/ICH\\_Q9%28R1%29\\_Guideline\\_Step4\\_2023\\_0126.pdf](https://database.ich.org/sites/default/files/ICH_Q9%28R1%29_Guideline_Step4_2023_0126.pdf)

International Organization for Standardization. (2011). *ISO/IEC 25010:2011 Systems and software engineering—Systems and software Quality Requirements and Evaluation (SQuaRE)—System and software quality models*. <https://www.iso.org/standard/35733.html>

International Organization for Standardization. (2018). *ISO/IEC 20000-1:2018 Information technology—Service management—Part 1: Service management system requirements*. <https://www.iso.org/standard/70636.html>

International Organization for Standardization. (2018). *ISO/IEC/IEEE 29148:2018 Systems and software engineering—Life cycle processes—Requirements engineering*. <https://www.iso.org/standard/72089.html>

International Organization for Standardization. (2019). *ISO 9241-210:2019 Ergonomics of human-system interaction — Part 210: Human-centred design for interactive systems*. <https://www.iso.org/standard/77520.html>

International Organization for Standardization, & International Electrotechnical Commission. (2022). *ISO/IEC 27001:2022 Information security, cybersecurity and privacy protection — Information security management systems — Requirements*. ISO.

International Society for Pharmaceutical Engineering. (2023). *ISPE Baseline® Guide: Volume 8 - Pharma 4.0™*. ISPE.

ISACA. (2019). *COBIT 2019 Framework: Introduction and Methodology*. ISACA.

Lugada, E., Komakech, H., Ochola, I., Mwebaze, S., Oteba, M. O., & Ladwar, D. O. (2022). Health supply chain system in Uganda: Current issues, structure, performance, and implications for systems strengthening. *Journal of Pharmaceutical Policy and Practice*, 15(1), 14. <https://doi.org/10.1186/s40545-022-00412-4>

Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30.

Mell, P., & Grance, T. (2011). *The NIST definition of cloud computing* (Special Publication 800-145). National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.SP.800-145>

Ministério da Saúde. (2020). *Portaria GM/MS N° 1.434, de 28 de maio de 2020. Institui o Programa Conecte SUS e altera a Portaria de Consolidação n° 1/GM/MS* (Instituye la Red Nacional de Datos de Salud - RNDS). Diário Oficial da União. <https://www.in.gov.br/en/web/dou/-/portaria-n-1.434-de-28-de-maio-de-2020-259143327>

Mwencha, M., Shieshia, M., Ombaka, J., Njenga, S., & Romero, L. (2017). eLMIS implementation in Kenya: Benefits for commodities availability. *Global Health: Science and Practice*, 5(4), 625–633. <https://doi.org/10.9745/GHSP-D-17-00293>

Nascimento, I. J. B., Abdulazeem, H., Vasanthan, L. T., Martinez, E. Z., Zucoloto, M. L., Østengaard, L., Azzopardi-Muscat, N., Zapata, T., & Novillo-Ortiz, D. (2023). Barriers and facilitators to utilizing digital health technologies by healthcare professionals. *npj Digital Medicine*, 6(1), 161. <https://doi.org/10.1038/s41746-023-00899-4>

National Institute of Standards and Technology. (2023). *Artificial Intelligence Risk Management Framework (AI RMF 1.0)* (NIST AI 100-1). U.S. Department of Commerce. <https://doi.org/10.6028/NIST.AI.100-1>

National Institute of Standards and Technology. (2024). *The NIST Cybersecurity Framework (CSF) 2.0* (NIST CSWP 29). U.S. Department of Commerce. <https://doi.org/10.6028/NIST.CSWP.29>

Nguyen, A., Lamouri, S., Pellerin, R., Tamayo, S., & Lekens, B. (2022). Data analytics in pharmaceutical supply chains: State of the art, opportunities, and challenges. *International Journal of Production Research*, 60(22), 6888–6907. <https://doi.org/10.1080/00207543.2021.1950937>

Oficina Normativa de Contratación y Adquisiciones del Estado. (2025). *Honducompras: Sistema de Información de Contratación y Adquisiciones*. Recuperado el 25 de enero de 2026, de <https://honducompras.gob.hn/>

Organización de las Naciones Unidas. (2015). *Transformar nuestro mundo: la Agenda*

2030 para el Desarrollo Sostenible (A/RES/70/1).  
[https://www.un.org/ga/search/view\\_doc.asp?symbol=A/RES/70/1&Lang=S](https://www.un.org/ga/search/view_doc.asp?symbol=A/RES/70/1&Lang=S)

Organización Mundial de la Salud. (2021). *Ethics and governance of artificial intelligence for health: WHO guidance*. <https://www.who.int/publications/i/item/9789240029200>

Organización Mundial de la Salud. (2024). *Medicamentos esenciales: Datos y cifras*. <https://www.who.int/es/news-room/fact-sheets/detail/essential-medicines>

Organización Mundial de la Salud. (2025). *The selection and use of essential medicines: Report of the WHO Expert Committee, 2025 (including the 24th WHO Model List of Essential Medicines)*. <https://www.who.int/groups/expert-committee-on-selection-and-use-of-essential-medicines>

Organización Panamericana de la Salud. (2017). *Information systems for health: A conceptual framework for developing the IS4H maturity model*. Pan American Health Organization.

Organización Panamericana de la Salud. (2021). *Roadmap for the digital transformation of the health sector in the Region of the Americas*. <https://iris.paho.org/handle/10665.2/54932>

Organización Panamericana de la Salud. (2022, 22 de octubre). *Proyectos de la OPS/OMS fortalecen sistema de salud Honduras*. <https://www.paho.org/es/noticias/22-10-2022-proyectos-opsoms-fortalecen-sistema-salud-honduras>

Organización Panamericana de la Salud. (2024). *Plan de acción para el fortalecimiento de los sistemas de información para la salud 2024-2030* (CE174/8). <https://www.paho.org/es/documentos/ce1748-plan-accion-fortalecimiento-sistemas-informacion-salud-2024-2030>

Parlamento Europeo y Consejo de la Unión Europea. (2025). *Reglamento (UE) 2025/327 relativo al Espacio Europeo de Datos Sanitarios*. Diario Oficial de la Unión Europea. <http://data.europa.eu/eli/reg/2025/327/oj>

Parlamento Europeo y Consejo de la Unión Europea. (2024). *Reglamento (UE) 2024/1689*

por el que se establecen normas armonizadas sobre inteligencia artificial. Diario Oficial de la Unión Europea. <http://data.europa.eu/eli/reg/2024/1689/oj>

Patton, M. Q. (2015). *Qualitative research & evaluation methods: Integrating theory and practice* (4th ed.). SAGE Publications.

Porter, M. E. (1979). How competitive forces shape strategy. *Harvard Business Review*, 57(2), 137–145.

Porter, M. E. (2008). The five competitive forces that shape strategy. *Harvard Business Review*, 86(1), 78–93.

Presidência da República. (2018). *Lei N° 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD)*. Diário Oficial da União. [http://www.planalto.gov.br/ccivil\\_03/\\_ato2015-2018/2018/lei/113709.htm](http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/113709.htm)

Rathipriya, R., Abdul Rahman, A. A., Dhamodharavadhani, S., Meero, A., & Yoganandan, G. (2023). Demand forecasting model for time-series pharmaceutical data using shallow and deep neural network model. *Neural Computing and Applications*, 35, 1945–1957. <https://doi.org/10.1007/s00521-022-07889-9>

Secretaría de Estado en el Despacho de Salud. (2024). *Acuerdo No. 5230-2023: Lista Nacional de Medicamentos Esenciales Honduras 2023-2025*. La Gaceta.

Secretaría de Salud de Honduras. (2024). *Hoja de ruta de transformación digital en salud de Honduras*. <https://honduras.bvsalud.org/wp-content/uploads/2025/03/Hoja-de-Ruta-Transformacion-Digital-en-Salud-de-Honduras.pdf>

Shadish, W. R., Cook, T. D., & Campbell, D. T. (2002). *Experimental and quasi-experimental designs for generalized causal inference*. Houghton Mifflin.

Shapiro, S. S., & Wilk, M. B. (1965). An analysis of variance test for normality (complete samples). *Biometrika*, 52(3–4), 591–611. <https://doi.org/10.1093/biomet/52.3-4.591>

Shukar, S., Zahoor, F., Hayat, K., Saeed, A., Gillani, A. H., Omer, S., Hu, S., Babar, Z.,

Fang, Y., & Yang, C. (2021). Drug shortage: Causes, impact, and mitigation strategies. *Frontiers in Pharmacology*, 12, 693426. <https://doi.org/10.3389/fphar.2021.693426>

Tavakol, M., & Dennick, R. (2011). Making sense of Cronbach's alpha. *International Journal of Medical Education*, 2, 53–55.

The Global Fund. (2023). *Results Report 2023*. <https://www.theglobalfund.org/en/results/>

The Open Group. (2022). *The TOGAF® Standard, 10th Edition*. <https://publications.opengroup.org/togaf-standard>

UNESCO. (2021). *Recommendation on the ethics of artificial intelligence*. UNESCO. <https://unesdoc.unesco.org/ark:/48223/pf0000380455>

Waller, M. A., & Fawcett, S. E. (2013). Data science, predictive analytics, and big data: A revolution that will transform supply chain design and management. *Journal of Business Logistics*, 34(2), 77–84. <https://doi.org/10.1111/jbl.12010>

Wang, R. Y., & Strong, D. M. (1996). Beyond accuracy: What data quality means to data consumers. *Journal of Management Information Systems*, 12(4), 5–33. <https://doi.org/10.1080/07421222.1996.11518099>

WHO Collaborating Centre for Drug Statistics Methodology. (2025). *Guidelines for ATC classification and DDD assignment 2025*. World Health Organization. [https://www.whocc.no/atc\\_ddd\\_index/](https://www.whocc.no/atc_ddd_index/)

Wilcoxon, F. (1945). *Individual comparisons by ranking methods*. *Biometrics Bulletin*, 1(6), 80–83. <https://doi.org/10.2307/3001968>


Yani, L. P. E., & Aamer, A. (2023). Demand forecasting accuracy in the pharmaceutical supply chain: A machine learning approach. *International Journal of Pharmaceutical and Healthcare Marketing*, 17(1), 1–23. <https://doi.org/10.1108/IJPHM-05-2021-0056>

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

## ANEXOS

### ANEXO I: ENCUESTA

<https://forms.gle/1AQjwoL4k5fe7Tf6A>




## Encuesta: Modelo informacional predictivo para medicamentos esenciales

**MAESTRÍA EN GESTIÓN DE TECNOLOGÍAS DE LA INFORMACIÓN**

**PROPUESTA DE  
MODELO DE PLATAFORMA DIGITAL CON ANALÍTICA E INTELIGENCIA ARTIFICIAL PARA  
OPTIMIZAR LA GESTIÓN INFORMACIONAL DE LA CADENA DE SUMINISTRO DE  
MEDICAMENTOS  
ESENCIALES EN FARMACIAS SIMAN**

**Propósito:** identificar requisitos (funcionales/no funcionales), compatibilidad tecnológica y condiciones de datos; además, recoger percepciones para el diseño de tableros y alertas. La participación es voluntaria, anónima y con fines académicos.

[garygonzalezpeda@gmail.com](mailto:garygonzalezpeda@gmail.com) [Cambiar cuenta](#) 

 No compartido

**\* Indica que la pregunta es obligatoria**

## ANEXO II: MATRIZ DE REQUERIMIENTOS



### MAESTRÍA EN GESTIÓN DE TECNOLOGÍAS DE LA INFORMACIÓN

### PROPUESTA DE MODELO DE PLATAFORMA DIGITAL CON ANALÍTICA E INTELIGENCIA ARTIFICIAL PARA OPTIMIZAR LA GESTIÓN INFORMACIONAL DE LA CADENA DE SUMINISTRO DE MEDICAMENTOS ESENCIALES EN FARMACIAS SIMAN

---

#### MATRIZ DE REQUERIMIENTOS

Objetivo Específico 1: Identificación de Requisitos

##### Información del Instrumento

<b>Estándar</b>	ISO/IEC/IEEE 29148:2018 + ISO/IEC 25010:2011
<b>Proyecto</b>	Modelo de Información con Capacidades Predictivas
<b>Cliente</b>	Farmacias Siman - San Pedro Sula
<b>Fecha</b>	
<b>Versión</b>	1.0
<b>Responsable</b>	Gary González Zepeda / Nayra Nicolle Valle Martínez

---

ANEXO III: MATRIZ DE DISPONIBILIDAD Y CALIDAD DE DATOS



**MAESTRÍA EN GESTIÓN DE TECNOLOGÍAS DE LA  
INFORMACIÓN**

**PROPUESTA DE MODELO DE PLATAFORMA DIGITAL CON  
ANALÍTICA E INTELIGENCIA ARTIFICIAL PARA OPTIMIZAR  
LA GESTIÓN INFORMACIONAL DE LA CADENA DE  
SUMINISTRO DE MEDICAMENTOS ESENCIALES EN  
FARMACIAS SIMAN**

---

**MATRIZ DE DISPONIBILIDAD/CALIDAD DE DATOS**

**Objetivo Específico 1: Identificación de Requisitos**

**Información del Instrumento**

<b>Estándar</b>	ISO/IEC/IEEE 29148:2018
<b>Proyecto</b>	Modelo de Información con Capacidades Predictivas
<b>Cliente</b>	Farmacias Siman - San Pedro Sula
<b>Fecha</b>	
<b>Versión</b>	1.0
<b>Responsable</b>	Gary González Zepeda / Nayra Nicolle Valle Martínez

---

**SECCIÓN A: FUENTES DE DATOS DISPONIBLES**

<b>ID</b>	<b>Fuente de Datos</b>	<b>Tipo</b>	<b>Disponibilidad</b>	<b>Período Histórico</b>	<b>Frecuencia Actualización</b>	<b>Formato</b>
FD-001						



**MAESTRÍA EN GESTIÓN DE TECNOLOGÍAS  
INFORMACIÓN**

**PROPUESTA DE MODELO DE PLATAFORMA DE  
ANALÍTICA E INTELIGENCIA ARTIFICIAL PARA  
LA GESTIÓN INFORMACIONAL DE LA CADENA  
DE SUMINISTRO DE MEDICAMENTOS EN LAS  
FARMACIAS SIMAN**

---

**MATRIZ DE EVALUACIÓN DE ALGORITMOS ML**

**Objetivo 2: Efectividad de técnicas de IA**

**Información del Instrumento**

<b>Estándar</b>	Hyndman & Athanasopoulos (2021) + Lundberg & Lee (2017)
<b>Proyecto</b>	Modelo de Información con Capacidades Predictivas
<b>Cliente</b>	Farmacias Siman - San Pedro Sula
<b>Fecha</b>	
<b>Versión</b>	1.0
<b>Responsable</b>	Gary González Zepeda / Nayra Nicolle Valle Martínez

## ANEXO V: SCRIPTS BACKTESTING AUTOMATIZADO



SCRIPTS BACKTESTING AUTOMATIZADO.py

## ANEXO VI: PROTOCOLO DE VALIDACIÓN WALK-FORWARD



PROTOCOLO DE VALIDACIÓN WALK-FORWARD.py

## ANEXO VII: PLANTILLA TOGAF ADM



**MAESTRÍA EN GESTIÓN DE TECNOLOGÍAS DE LA  
INFORMACIÓN**

**PROPUESTA DE MODELO DE PLATAFORMA DIGITAL CON  
ANALÍTICA E INTELIGENCIA ARTIFICIAL PARA OPTIMIZAR  
LA GESTIÓN INFORMACIONAL DE LA CADENA DE  
SUMINISTRO DE MEDICAMENTOS ESENCIALES EN  
FARMACIAS SIMAN**

---

### PLANTILLAS TOGAF ADM

Objetivo Especifico 3: Especificar arquitectura

#### Información del Instrumento

<b>Estándar</b>	TOGAF® Standard, 10th Edition
<b>Proyecto</b>	Modelo de Información con Capacidades Predictivas
<b>Cliente</b>	Farmacias Siman - San Pedro Sula
<b>Fecha</b>	
<b>Versión</b>	1.0
<b>Responsable</b>	Gary González Zepeda / Nayra Nicolle Valle Martínez

---

## ANEXO VIII: CHECKLIST WELL-ARCHITECTED GCP + GUÍA SRE



### MAESTRÍA EN GESTIÓN DE TECNOLOGÍAS DE LA INFORMACIÓN

#### PROPUESTA DE MODELO DE PLATAFORMA DIGITAL CON ANALÍTICA E INTELIGENCIA ARTIFICIAL PARA OPTIMIZAR LA GESTIÓN INFORMACIONAL DE LA CADENA DE SUMINISTRO DE MEDICAMENTOS ESENCIALES EN FARMACIAS SIMAN

#### CHECKLIST WELL-ARCHITECTED GCP + GUÍA SRE

Objetivo Especifico 3: Especificar Arquitectura en la Nube

##### Información del Instrumento

Estándar	Google Cloud Platform Well-Architected Framework
Proyecto	Modelo de Información con Capacidades Predictivas
Cliente	Farmacias Siman - San Pedro Sula
Fecha	
Versión	1.0
Responsable	Gary González Zepeda / Nayra Nicolle Valle Martínez

#### A. CHECKLIST WELL-ARCHITECTED: RENDIMIENTO

Fuente: Google Cloud Architecture Framework - Performance Efficiency Pillar

ID	Criterio de Rendimiento	Aplicable	Estado	Observaciones
PER-001	Selección apropiada de servicios compute	<input type="checkbox"/> Sí <input type="checkbox"/> No	<input type="checkbox"/> ✓ <input type="checkbox"/> ⚠ <input type="checkbox"/> ✗	



**MAESTRÍA EN GESTIÓN DE TECNOLOGÍAS DE LA  
INFORMACIÓN**

**PROPUESTA DE MODELO DE PLATAFORMA DIGITAL CON  
ANALÍTICA E INTELIGENCIA ARTIFICIAL PARA OPTIMIZAR  
LA GESTIÓN INFORMACIONAL DE LA CADENA DE  
SUMINISTRO DE MEDICAMENTOS ESENCIALES EN  
FARMACIAS SIMAN**

---

**MARCO DE EVALUACIÓN DE VIABILIDAD**

**Objetivo Específico 4: Establecer Marco de Evaluación**

**Información del Instrumento**

<b>Estándar</b>	Hyndman & Athanasopoulos (2021) + Tavakol & Dennick (2011)
<b>Proyecto</b>	Modelo de Información con Capacidades Predictivas
<b>Cliente</b>	Farmacias Siman - San Pedro Sula
<b>Fecha</b>	
<b>Versión</b>	1.0
<b>Responsable</b>	Gary González Zepeda / Nayra Nicolle Valle Martínez

---

**MÉTRICAS Y UMBRALES DE DESEMPEÑO**

**PARTE I: MÉTRICAS DE VIABILIDAD TÉCNICA**

**A. Precisión Predictiva (Validación Fuera de Muestra)**

## ANEXO X: MATRIZ DE UTILIDAD OPERATIVA



### MAESTRÍA EN GESTIÓN DE TECNOLOGÍAS DE LA INFORMACIÓN

#### PROPUESTA DE MODELO DE PLATAFORMA DIGITAL CON ANALÍTICA E INTELIGENCIA ARTIFICIAL PARA OPTIMIZAR LA GESTIÓN INFORMACIONAL DE LA CADENA DE SUMINISTRO DE MEDICAMENTOS ESENCIALES EN FARMACIAS SIMAN

---

#### MATRIZ DE UTILIDAD OPERATIVA

Objetivo Especifico 4: Marco de evaluación

##### Información del Instrumento

<b>Estándar</b>	
<b>Proyecto</b>	Modelo de Información con Capacidades Predictivas
<b>Cliente</b>	Farmacias Siman - San Pedro Sula
<b>Fecha</b>	
<b>Versión</b>	1.0
<b>Responsable</b>	Gary González Zepeda / Nayra Nicolle Valle Martínez

---

## ANEXO XI: SCRIPT PYTHON UTILIDAD DE ALERTAS



SCRIPT PYTHON UTILIDAD DE ALERTAS.py

## ANEXO XII: MATRIZ DE TRAZABILIDAD REQUISITOS-COMPONENTES



### MAESTRÍA EN GESTIÓN DE TECNOLOGÍAS DE LA INFORMACIÓN

#### PROPUESTA DE MODELO DE PLATAFORMA DIGITAL CON ANALÍTICA E INTELIGENCIA ARTIFICIAL PARA OPTIMIZAR LA GESTIÓN INFORMACIONAL DE LA CADENA DE SUMINISTRO DE MEDICAMENTOS ESENCIALES EN FARMACIAS SIMAN

---

#### MATRIZ DE TRAZABILIDAD REQUISITOS- COMPONENTES

Objetivo Especifico 3: Especificar Arquitectura en la Nube

##### Información del Instrumento

Estándar	TOGAF® Standard, 10th Edition - Architecture Requirements Specification
Proyecto	Modelo de Información con Capacidades Predictivas
Cliente	Farmacias Siman - San Pedro Sula
Fecha	
Versión	1.0
Responsable	Gary González Zepeda / Nayra Nicolle Valle Martínez

---

##### INSTRUCCIONES DE USO

Objetivo: Asegurar trazabilidad completa entre requisitos funcionales/no funcionales identificados en Objetivo 1 y componentes arquitectónicos especificados en Objetivo 3.

##### Criterios de Cumplimiento:

- CUBIERTO: Componente satisface completamente el requisito

## ANEXO XIII: FRAGMENTO DEL INSTRUMENTO TÉCNICO - SCRIPT ETL DE EXTRACCIÓN (BIGQUERY)



Script ETL de Extracción (BigQuery).sql