

INTELIGENCIA DE NEGOCIOS, PARA EL PROCESO DE TOMA DE DECISIONES EN EL SECTOR SALUD

Primera Edición Digital

HN
Ho Nexus
EDITORIAL

William George Paucar Palomino
Orlando Clemente Iparraguirre Villanueva
Rosario Vargas Roncal
Gael Campos Truyenque



INTELIGENCIA DE NEGOCIOS, PARA EL PROCESO DE TOMA DE DECISIONES EN EL SECTOR SALUD

***Primera Edición
Digital***



William George Paucar Palomino
Orlando Clemente Iparraguirre Villanueva
Rosario Vargas Roncal
Gael Campos Truyenque

HN
HoNexus
EDITORIAL

INTELIGENCIA DE NEGOCIOS, PARA EL PROCESO DE TOMA DE DECISIONES EN EL SECTOR SALUD

© William George Paucar Palomino.
© Orlando Clemente Iparraguirre Villanueva.
© Rosario Vargas Roncal.
© Gael Campos Truyenque.

Editor de contenido: Natalia Beltran
Diseño de cubierta: Ho Nexus

1ª edición digital, mayo 2026

Editado por:

© HO NEXUS E.I.R.L.
Dirección legal: Urb. Paseo del Mar Mz L4, Lt 33
Nuevo Chimbote, Santa, Áncash - Perú
Correo electrónico; ed.honexus@gmail.com
teléfono: 978 653 152
<https://books.honexus.org>
DOI: <https://doi.org/10.70504/978-612-99401-3-7>

Reservados todos los derechos de publicación en cualquier idioma; siendo su contenido protegido por la Ley vigente que establece penas de prisión y/o multas a quienes intencionadamente reprodujeran o plagiaran, en todo o en parte, una obra literaria, artística o científica.

Depósito Legal: 2026- 05470
ISBN: 978-612-99401-3-7

Revisión por pares:

Este libro (o monografía) fue sometido a evaluación de pares mediante el sistema de doble ciego (doubleblinded review), garantizando la calidad, pertinencia, ética y rigor académico de la obra, conforme a los estándares internacionales de revisión científica y las políticas editoriales de Ho Nexus.

ÍNDICE

PRÓLOGO	5
RESUMEN.....	7
INTRODUCCIÓN	9
CAPÍTULO 1:	13
El desafío de decidir en el sector salud	13
1.1 ¿Por qué es tan difícil tomar buenas decisiones en salud?.....	14
1.2 Consecuencias de la ineficiencia: reportes lentos, datos duplicados, insatisfacción	15
1.3 Objetivos del manuscrito y preguntas que responde	17
CAPÍTULO 2: Fundamentos de la Inteligencia de Negocios	20
2.1 Definición y ciclo de vida de la BI.....	21
2.2 Beneficios demostrados en el sector salud	22
2.3 Proceso ETL: extraer, transformar, cargar (explicación sencilla)	24
2.4 Data Warehouse y Data Mart: conceptos clave.....	25
2.5 Herramientas populares: Power BI, Tableau, Qlik	26
2.6 Metodología de Ralph Kimball: el enfoque dimensional.....	27
CAPÍTULO 3: Contexto del estudio: la Red de Salud Leoncio Prado	31
3.1 Ubicación, población y estructura asistencial	32
3.2 Misión, visión y objetivos estratégicos.....	33
3.3 Diagnóstico inicial: ¿cómo se tomaban las decisiones antes de la BI?	35
3.4 Identificación de los problemas específicos (tiempos, volumen, análisis, satisfacción)	37
CAPÍTULO 4: Diseño metodológico para evaluar la mejora	41
4.1 Enfoque cuasi-experimental y diseño pre-prueba / post-prueba.....	42
4.2 Población, muestra y tipo de muestreo.....	44
4.3 Variables e indicadores de la investigación.....	45
4.4 Instrumentos de recolección de datos (fichas de registro, encuestas).....	46
4.5 Herramientas estadísticas: R Project, prueba de normalidad, t de Student	48
CAPÍTULO 5: Construcción de la solución de Inteligencia de Negocios	52
5.1 Requerimientos funcionales y no funcionales.....	53
5.2 Modelo de datos dimensional (matriz de BUS y estrella de hechos)	54
5.3 Diseño físico de las tablas (anemia, IRAS, EDAS, emergencias, COVID-19)	56
5.4 Arquitectura de la solución (SQL Server, Visual Studio, SSIS).....	59
5.5 Desarrollo del proceso ETL (casos prácticos)	61

5.6 Creación del cubo OLAP con Analysis Services	63
5.7 Conexión a Power BI y construcción de dashboards interactivos	64
CAPÍTULO 6: Resultados obtenidos	68
6.1 Indicador I1: Tiempo de generación de reportes (de 202 min a 3.3 min)	69
6.2 Indicador I2: Cantidad de reportes por día (de 30 a 63)	70
6.3 Indicador I3: Tiempo para analizar información (de 58 min a 14 min).....	71
6.4 Indicador I4: Nivel de satisfacción del usuario (incremento: 30% → 60% alto)	72
6.5 Prueba de normalidad y contraste de hipótesis (t de Student, $p < 0.05$).....	74
CAPÍTULO 7: Discusión y lecciones aprendidas	79
7.1 Comparación con estudios similares en el sector salud y otros sectores	80
7.2 Factores críticos de éxito en la implementación de BI en salud	82
7.3 Limitaciones encontradas (calidad de datos, capacitación del personal).....	84
7.4 Recomendaciones para futuros proyectos	86
CAPÍTULO 8: Conclusiones y recomendaciones para gestores del sector salud	89
8.1 Síntesis de los hallazgos	90
8.2 Recomendaciones prácticas: capacitar, estandarizar fuentes, mantener el sistema	91
8.3 Próximos pasos: hacia la analítica predictiva y la inteligencia artificial	93
BIBLIOGRAFÍA	97

PRÓLOGO

Cuando hablamos de mejorar la salud de una población, solemos pensar en médicos, medicamentos, infraestructura hospitalaria o campañas de vacunación. Pero hay un factor silencioso que condiciona todos los demás: la calidad de la información disponible para decidir.

Durante años, los directivos de hospitales y redes de salud han debido tomar decisiones cruciales como asignar presupuesto, redistribuir personal o lanzar una campaña preventiva basándose en reportes que llegaban tarde, datos inconsistentes o simplemente en la intuición. Esta realidad no solo genera ineficiencia, sino que puede tener consecuencias directas en la vida de los pacientes.

Esta investigación nace de una experiencia real y exitosa en la Red de Salud Leoncio Prado (Inocente Eugenio, 2024), una red pública peruana que atendía a más de 200,000 personas. Allí, los procesos de toma de decisiones adolecían de lentitud, baja productividad de reportes y escasa satisfacción de los usuarios. Aplicando una metodología rigurosa de Inteligencia de Negocios (BI), logramos revertir esa situación.

En estas páginas, los autores compartimos no solo los resultados obtenidos, sino también el camino recorrido: desde la identificación de los problemas hasta la construcción de dashboards interactivos con Power BI, pasando por la limpieza de datos y el diseño dimensional. Lo hacemos con un lenguaje claro, evitando tecnicismos innecesarios, para que cualquier gestor o profesional del sector salud pueda comprender el proceso y replicarlo en su organización.

El propósito último de esta investigación es demostrar que la Inteligencia de Negocios no es una moda tecnológica, sino una herramienta estratégica que, bien aplicada, mejora la eficiencia, optimiza los recursos y, en última instancia, contribuye a tomar decisiones que salvan vidas.

Los autores

Tingo María, 2026

RESUMEN

En el sector salud, la toma de decisiones oportuna y basada en evidencia puede significar la diferencia entre una atención eficaz y una falla del sistema. Sin embargo, muchas redes y establecimientos de salud enfrentan dificultades para generar reportes ágiles, analizar grandes volúmenes de datos y satisfacer las necesidades de información de sus directivos. Este manuscrito presenta una solución práctica basada en Inteligencia de Negocios (Business Intelligence, BI) aplicada a un caso real: la Red de Salud Leoncio Prado (Huánuco, Perú) (Inocente Eugenio, 2024).

Siguiendo la metodología dimensional de (Kimball, 1996) los autores construyeron un sistema que integra datos de diferentes fuentes (anemia, infecciones respiratorias, enfermedades diarreicas, emergencias y COVID-19), los transforma mediante procesos ETL y los visualiza en dashboards interactivos con Power BI. Los resultados fueron notables: reducción del tiempo de generación de reportes de 202 a 3.3 minutos, aumento de la cantidad de reportes diarios de 30 a 63, disminución del tiempo de análisis de 58 a 14 minutos, e incremento de la satisfacción del usuario del 30% al 60%.

Escrito en un lenguaje claro y accesible, el manuscrito explica desde los conceptos fundamentales de la Inteligencia de Negocios hasta los detalles técnicos de implementación, convirtiéndose en una base para gestores de salud, profesionales de TI y estudiantes interesados en la transformación digital del sector.

Palabras clave: Inteligencia de Negocios, Toma de decisiones, Sector salud, Power BI, Data Warehouse, Metodología Kimball.

INTRODUCCIÓN

Vivimos en la era de los datos. Cada día, los sistemas de información sanitaria generan volúmenes enormes de información: historias clínicas electrónicas, registros de laboratorio, datos de farmacia, encuestas de satisfacción, vigilancia epidemiológica, entre muchos otros. Sin embargo, como advierte la (World Health Organization (WHO), 2021), el simple almacenamiento de datos no mejora la salud de las poblaciones; lo que realmente marca la diferencia es la capacidad de transformar esos datos en información útil, la información en conocimiento y el conocimiento en decisiones efectivas.

La inteligencia empresarial (BI) es precisamente el conjunto de tecnologías, procesos y metodologías que hacen posible esta transformación (Turban et al., 2019). Se ha visto que la BI actúa como un aliado indispensable para la vigilancia epidemiológica, la gestión de camas hospitalarias, el control de medicamentos, la evaluación de políticas públicas y la mejora de la eficiencia operativa en el ámbito de la salud (Mejia Huayhua et al., 2023). Sin embargo, la BI no es fácil de implementar en el sector salud. Basado en una revisión sistemática publicada, entre el 70% y el 80% de los proyectos de BI fracasan o no cumplen con los objetivos esperados, principalmente debido a problemas de calidad de los datos, falta de alineación con las necesidades reales de los usuarios y resistencia al cambio organizacional (Ain et al., 2019). Para mitigar estas amenazas, es importante adoptar un enfoque establecido, como el descrito por Ralph Kimball, que involucra modelos dimensionales y desarrollo iterativo (Kimball & Ross, 2013).

Este manuscrito investiga el proceso de implementación de una solución de BI en la Red de Salud Leoncio Prado en la región de Huánuco, Perú (Inocente Eugenio, 2024). Más de 200,000 personas son atendidas por esta red, que está compuesta por 30 establecimientos de salud. Antes del proyecto, el proceso de toma de decisiones era extremadamente ineficiente: el tiempo promedio de generación de informes era de 202 minutos, solo se producían 30 informes por día, el análisis de la información requería casi 58 minutos, y la satisfacción de los usuarios (gerentes y jefes de departamento) era baja (solo el 30% la calificaba como alta).

Aplicamos la metodología Kimball utilizando herramientas ampliamente difundidas: Microsoft SQL Server como motor de base de datos, Visual Studio Community con Integration Services para los procesos de extracción, transformación y carga (ETL), Analysis Services para construir el cubo dimensional, y Power BI Desktop para los dashboards interactivos. Power BI ha sido reconocido por Gartner como el líder del cuadrante mágico para plataformas de análisis y BI durante seis años consecutivos (Gartner, 2025).

Los resultados obtenidos superaron las expectativas: reducción del 98% en el tiempo de generación de reportes (de 202 a 3.3 minutos), incremento del 112% en la cantidad de reportes diarios (de 30 a 63), disminución del 75% en el tiempo de análisis (de 58 a 14 minutos) y elevación de la satisfacción alta hasta el 60%. Estos hallazgos son consistentes con estudios similares realizados en hospitales de Chile (Hidalgo et al., 2020) y en otros sectores, confirmando que la Inteligencia de Negocios es una herramienta poderosa para la gestión sanitaria.

El manuscrito está estructurado en ocho capítulos que guían al lector desde el diagnóstico del problema hasta la implementación y evaluación de la solución. No se requieren conocimientos profundos de programación o estadística; hemos procurado explicar cada concepto técnico con ejemplos sencillos. Al final, el lector encontrará recomendaciones prácticas para replicar esta experiencia en su propia organización.

Invitamos a los directivos de salud, profesionales de tecnologías de la información, estudiantes y ciudadanos interesados a sumergirse en estas páginas. Descubrirán que la Inteligencia de Negocios no es solo una herramienta tecnológica, sino una estrategia fundamental para optimizar la toma de decisiones en el sector salud.



CAPÍTULO 1:

El desafío de decidir en el sector salud

1.1 ¿Por qué es tan difícil tomar buenas decisiones en salud?

- Gran volumen de datos provenientes de múltiples fuentes y sistemas.
- Información fragmentada y sin integración.
- Procesos manuales y dependientes de hojas de cálculo.
- Falta de indicadores confiables y oportunos.
- Decisiones basadas en la experiencia más que en evidencia.



1.2 Consecuencias de la ineficiencia: reportes lentos, datos duplicados, insatisfacción

-  Reportes lentos que impiden respuestas oportunas.
-  Datos duplicados o inconsistentes que generan confusión y reprocesos.
-  Ineficiencia operativa y uso inadecuado de recursos.
-  Insatisfacción de pacientes, usuarios y personal de salud.
-  Riesgos en la calidad del servicio y en la toma de decisiones críticas.

1.3 Objetivos del libro y preguntas que responde

Objetivo general:
Mostrar cómo la Inteligencia de Negocios (BI) puede transformar los datos en información útil y oportuna, para apoyar decisiones efectivas que mejoren la gestión y los resultados en el sector salud.

Este libro responde:

- ¿Qué es la Inteligencia de Negocios y cómo se aplica en salud?
- ¿Qué datos necesito y cómo organizarlos?
- ¿Cómo construir indicadores y tableros que realmente aporten valor?
- ¿Cómo implementar BI en mi organización de salud paso a paso?
- ¿Qué beneficios concretos puedo lograr con BI en salud?



 **Decidir mejor, a tiempo y con datos confiables, salva recursos y vidas.**

1.1 ¿Por qué es tan difícil tomar buenas decisiones en salud?

Las decisiones en el ámbito de la salud nunca han sido simples. Diariamente, los gestores de hospitales, centros de salud y redes de salud se enfrentan a preguntas complicadas: ¿Cuántas camas de UCI deberían estar disponibles para la próxima semana? ¿En qué distritos es más urgente una campaña contra la anemia? ¿Cómo deberían asignar el escaso presupuesto en términos de medicamentos, personal e infraestructura? No se trata solo de complejidad clínica o administrativa, ya que aquí hay una profunda dificultad: la información para responder a estas preguntas a menudo llega tarde, de manera parcial o no es confiable. Como señalaron (Kurniawan et al., 2021), el proceso de toma de decisiones es crítico para cualquier organización, ya que la toma de decisiones es fundamental para la realización de objetivos, un uso eficiente de los recursos y la motivación del personal. Pero se vuelve más difícil en el ámbito de la salud. En primer lugar, los datos se producen en muchos tipos de sistemas y en todo tipo de formatos (historias clínicas, registros de laboratorio, sistemas de gestión, etc.). Los equipos de estadística y planificación, por otro lado, tienen que lidiar con operaciones manuales, recopilando información en hojas de cálculo que rápidamente quedan obsoletas.

La literatura especializada ha documentado que muchas organizaciones enfrentan fracasos en la implementación de herramientas de apoyo a la decisión. (Ain et al., 2019) reportan que las tasas de fracaso de proyectos de Business Intelligence oscilan entre el 70% y el 80%, debido a problemas tanto tecnológicos como de gestión. En el sector

salud, esta realidad no es ajena: se invierte en software, pero no se logra que los directivos confíen en los datos o que los reportes lleguen a tiempo.

Además, la gestión de la información en un entorno dinámico y globalizado se ha vuelto crítica para la supervivencia de las organizaciones. Utilizar la información para mejorar los resultados de una institución sanitaria es fundamental para su crecimiento y éxito (Diario Gestión, 2014) Citado en (Inocente Eugenio, 2024).

En resumen, la dificultad para tomar buenas decisiones en salud no es un problema de voluntad o capacidad intelectual de los gestores, sino un problema estructural de disponibilidad, calidad y oportunidad de la información.

1.2 Consecuencias de la ineficiencia: reportes lentos, datos duplicados, insatisfacción

¿Qué ocurre cuando una red de salud no cuenta con un sistema ágil de generación de reportes? Las consecuencias se multiplican y afectan a todos los niveles de la organización.

Reportes lentos

En la Red de Salud Leoncio Prado, objeto de estudio de este manuscrito, el tiempo promedio para generar un reporte solicitado por la gerencia era de 202 minutos (más de tres horas). Esto significa que si un directivo necesitaba saber, por ejemplo, cuántos casos de infección respiratoria aguda se habían registrado en la última semana en el distrito

de Rupa-Rupa, debía esperar gran parte de su jornada laboral para obtener la respuesta. Para entonces, la situación ya podía haber cambiado.

Datos duplicados e inconsistentes

Al no existir una base de datos única y confiable, los equipos de trabajo solían extraer información de distintas fuentes, obteniendo resultados diferentes. Esto generaba desconfianza y obligaba a invertir tiempo adicional en verificar los números. La duplicación de información era una práctica común, lo que aumentaba el riesgo de errores y retrasaba aún más la toma de decisiones.

Insatisfacción del personal y los usuarios

La lentitud y la poca fiabilidad de los reportes afectaban la moral del personal administrativo y estadístico, que a menudo trabajaba horas extras para cumplir con los requerimientos. Pero lo más grave era la insatisfacción de los usuarios finales del sistema (directivos, jefes de área, planificadores). En la medición inicial (pre-prueba), solo el 30% de los usuarios calificaba como “alto” su nivel de satisfacción con el proceso de toma de decisiones. La mayoría lo consideraba “medio” o “bajo”.

Además, como señala (Inocente Eugenio, 2024), basada en (Herbert A. Simon, 1979), la toma de decisiones en entornos organizacionales es compleja y requiere no solo información, sino también marcos conceptuales que permitan interpretarla. Cuando la información no está

disponible en el momento adecuado, los gestores recurren a la intuición o a decisiones apresuradas, lo que puede derivar en una mala asignación de recursos y, en el peor de los casos, en daños a la salud de la población.

1.3 Objetivos del manuscrito y preguntas que responde

Esta investigación nace con un propósito claro: demostrar que es posible optimizar el proceso de toma de decisiones en el sector salud mediante la aplicación de la Inteligencia de Negocios (Business Intelligence, BI), y ofrecer una orientación práctica para lograrlo.

Objetivos específicos del manuscrito

- Describir los problemas concretos que afectan la toma de decisiones en una red de salud pública (tiempos de generación de reportes, cantidad de informes diarios, tiempo de análisis y satisfacción del usuario).
- Explicar los fundamentos de la Inteligencia de Negocios y la metodología de Ralph Kimball, adaptándolos al contexto sanitario.
- Presentar el diseño e implementación de una solución de BI, desde la extracción y transformación de datos hasta la creación de dashboards interactivos con Power BI.
- Mostrar los resultados cuantitativos y cualitativos obtenidos en la Red de Salud Leoncio Prado, validados con pruebas estadísticas.
- Ofrecer recomendaciones prácticas para que otras instituciones de salud puedan replicar esta experiencia.

Preguntas que responde el manuscrito

A lo largo de los capítulos, el lector encontrará respuesta a interrogantes como:


- 1) ¿Por qué los sistemas tradicionales de reportes fallan en el sector salud?
- 2) ¿Qué es la Inteligencia de Negocios y cómo puede aplicarse en un hospital o red de salud?
- 3) ¿Qué metodología seguir para garantizar el éxito de un proyecto de BI?
- 4) ¿Cuánto tiempo se puede reducir en la generación de reportes? ¿En cuánto se puede aumentar la cantidad de informes diarios?
- 5) ¿Cómo medir la mejora en la satisfacción de los usuarios?
- 6) ¿Qué herramientas tecnológicas son más adecuadas y accesibles para una institución pública con recursos limitados?
- 7) ¿Cuáles son los factores críticos de éxito y las lecciones aprendidas de un caso real?

Este texto no es un tratado teórico abstracto. Es el relato de una intervención real, con aciertos y dificultades, que logró transformar la manera en que una red de salud toma decisiones. Y está escrito para que cualquier gestor, profesional de TI o estudiante pueda entenderlo y aplicarlo.



CAPÍTULO 2:

Fundamentos de la Inteligencia de Negocios



Antes de sumergirnos en el caso práctico de la Red de Salud Leoncio Prado, es necesario comprender qué es la Inteligencia de Negocios, por qué es útil y cómo funciona. Este capítulo ofrece una introducción clara y sencilla a los conceptos fundamentales de la BI.

2.1 Definición y ciclo de vida de la BI

La Inteligencia de Negocios (Business Intelligence, BI) es mucho más que una herramienta o un software. Es un proceso que transforma datos en información, y la información en conocimiento útil para la toma de decisiones.

Existen varias definiciones de autores reconocidos. (Davenport & H., 2010) la describe como “un proceso de transformar datos en información, y la información en conocimiento, que permite la toma de decisiones efectivas en los negocios”. Por su parte, (Turban et al., 2019) amplían esta visión: “la inteligencia de negocios es un enfoque integral que utiliza datos históricos, actuales y predictivos para proporcionar información a las empresas y apoyar la toma de decisiones informadas”. Finalmente, (Alnoukari et al., 2012) añaden que la BI se refiere al “conjunto de tecnologías, procesos y herramientas que permiten a las organizaciones convertir datos en información valiosa para la toma de decisiones estratégicas”.

El ciclo de vida de la BI

El proceso de BI no es lineal, sino un ciclo continuo que se repite constantemente. Consta de ocho etapas principales:

- 1) **Extracción de datos:** se recopilan datos de diversas fuentes (bases de datos, sistemas transaccionales, redes sociales, etc.) de manera automatizada.

- 2) **Transformación de datos:** se limpian y preparan los datos (eliminación de duplicados, corrección de errores, estandarización de formatos).
- 3) **Almacenamiento de datos:** los datos limpios se guardan en un almacén de datos (Data Warehouse) o base de datos analítica.
- 4) **Análisis de datos:** se aplican técnicas estadísticas o de minería de datos para descubrir patrones y tendencias.
- 5) **Generación de informes y paneles:** los resultados se presentan en informes, paneles de control y visualizaciones interactivas.
- 6) **Toma de decisiones:** los directivos utilizan la información para evaluar opciones y tomar decisiones.
- 7) **Implementación de decisiones:** se ejecutan los cambios planificados (estrategias, asignación de recursos, etc.).
- 8) **Evaluación y retroalimentación:** se mide el impacto de las decisiones y se retroalimenta el ciclo para mejorar continuamente.

Este ciclo es iterativo, lo que significa que las organizaciones que adoptan BI aprenden y se ajustan permanentemente, mejorando su capacidad de respuesta.

2.2 Beneficios demostrados en el sector salud

La BI no es una moda pasajera. En el sector salud, sus beneficios han sido ampliamente documentados (ver Tabla 1). A continuación, destacamos los más relevantes:

Beneficio	Descripción aplicada a salud
Mejora de la toma de decisiones	Proporciona información precisa y oportuna para decisiones clínicas y administrativas.
Aumento de la eficiencia operativa	Automatiza la generación de reportes y reduce la carga manual del personal.
Optimización de recursos	Permite asignar presupuestos, camas y personal donde más se necesitan.
Mejora en la retención de pacientes	Identifica patrones de abandono de tratamientos y ayuda a diseñar estrategias de seguimiento.
Detección de oportunidades de salud pública	Permite identificar brotes epidemiológicos o zonas con baja cobertura de vacunación.
Gestión de riesgos mejorada	Monitorea indicadores de seguridad del paciente y eventos adversos.
Mejora de la planificación estratégica	Facilita la planificación basada en datos históricos y tendencias.
Cumplimiento regulatorio	Ayuda a generar los reportes exigidos por ministerios de salud y organismos de control.

**Tabla basada en (Turban et al., 2019), (Davenport & H., 2010), y (Laudon & Laudon, 2004).*

Estudios recientes en el ámbito sanitario confirman estos beneficios. Por ejemplo, (Mejia Huayhua et al., 2023) implementaron un prototipo de BI para la vigilancia de salud pública en la región de Arequipa (Perú), logrando identificar situaciones de pandemia y evaluar la inmunidad de la población. En Chile, (Hidalgo et al., 2020) construyeron

un Datamart para apoyar la toma de decisiones en una unidad de docencia hospitalaria, mejorando la disponibilidad de información.

2.3 Proceso ETL: extraer, transformar, cargar (explicación sencilla)

Uno de los pilares de cualquier solución de BI es el proceso ETL (Extract, Transform, Load). Es como la cocina de un restaurante: los ingredientes (datos) llegan de distintos proveedores (fuentes), se limpian y se cortan (transformación), y finalmente se sirven en el plato (carga) para que el comensal (usuario) los disfrute.

Extracción (Extract)

Se obtienen datos de múltiples fuentes: bases de datos, archivos Excel, sistemas Legacy, etc. Es importante que la extracción sea automática y periódica para garantizar la frescura de los datos.

Transformación (Transform)

Aquí se aplican reglas para limpiar y homogeneizar los datos:

- Eliminación de registros duplicados.
- Corrección de datos erróneos o faltantes.
- Estandarización de formatos (fechas, códigos, etc.).
- Enriquecimiento con datos adicionales.
- Filtrado de información irrelevante.

Carga (Load)

Finalmente, los datos transformados se cargan en un Data Warehouse o Data Mart, donde quedarán disponibles para su análisis y visualización.

Ejemplo sencillo: Supongamos que una red de salud tiene datos de consultas en tres sistemas distintos: uno registra la edad del paciente como “años”, otro como “fecha de nacimiento”, y otro tiene edades mal escritas (“treinta y dos”). El proceso ETL unifica todo: calcula la edad a partir de la fecha de nacimiento, corrige los textos y carga un único campo “edad” en el Data Warehouse.

2.4 Data Warehouse y Data Mart: conceptos clave

Data Warehouse (almacén de datos) es un repositorio centralizado que integra datos históricos y actuales de toda una organización. Está optimizado para consultas y análisis, no para transacciones diarias.

Dos grandes autores propusieron enfoques diferentes:

- **(Inmon, 2005)** Aboga por un Data Warehouse corporativo único que sirva como “única fuente de verdad” (arquitectura top-down).
- **(Kimball, 1996)** Prefiere construir primero Data Marts (almacenes de datos departamentales o temáticos) y luego integrarlos (arquitectura bottom-up). Este último enfoque es más ágil y práctico para la mayoría de las organizaciones .

Un Data Mart es una subsección del Data Warehouse, enfocada en las necesidades de un área específica (por ejemplo, el Data Mart de epidemiología o el Data Mart de emergencias). Los Data Marts son más

pequeños, más rápidos de construir y más fáciles de entender para los usuarios finales.

En nuestro caso, construimos un Data Mart multidimensional centrado en la atención de pacientes, con tablas de hechos (medidas cuantitativas) y tablas de dimensiones (contexto: tiempo, ubicación, persona, etc.).

2.5 Herramientas populares: Power BI, Tableau, Qlik

Existen muchas herramientas de BI en el mercado. Las más utilizadas en 2025 son:

Herramienta	Característica principal	Ideal para...
Microsoft Power BI	Integración con el ecosistema Microsoft, precios accesibles, versión gratuita.	Organizaciones públicas, pequeñas y medianas empresas.
Tableau	Potentes visualizaciones interactivas, gran flexibilidad.	Empresas con presupuesto amplio y necesidades de visualización avanzada.
Qlik (QlikView/Qlik Sense)	Motor de datos asociativo que permite exploración libre.	Usuarios que necesitan descubrir relaciones no predeterminadas.

**Basado en (Inocente Eugenio, 2024)*

En este manuscrito utilizamos Power BI por varias razones:

- Ha sido reconocido por (Gartner, 2025) como líder del Cuadrante Mágico de Plataformas Analíticas y de BI por decimosexto año consecutivo.
- Su relación calidad-precio es inmejorable, especialmente para instituciones públicas.
- Se integra perfectamente con Microsoft SQL Server y Azure, las plataformas que empleamos.

Nota: (Gartner, 2025) Destaca que Power BI lidera el mercado por su integración con Microsoft 365, Teams y Azure Synapse, además de su amplia gama de capacidades analíticas.

2.6 Metodología de Ralph Kimball: el enfoque dimensional

Ralph Kimball (1943-2013) fue un pionero del Data Warehousing. Su metodología se basa en el modelado dimensional, que organiza la información en tablas de hechos y tablas de dimensiones (Kimball, 1996).

Tablas de hechos

Contienen medidas cuantitativas (números que se pueden sumar o promediar). Por ejemplo: cantidad de pacientes, número de atenciones, total de camas ocupadas.

Tablas de dimensiones

Contienen atributos descriptivos que dan contexto a las medidas. Por ejemplo: fecha, ubicación (departamento, provincia, distrito), paciente (edad, sexo), establecimiento de salud.

El ciclo de vida de Kimball

La metodología propone 8 pasos iterativos:

- 1) **Requerimientos del negocio:** comprender qué necesita la organización.
- 2) **Diseño dimensional:** crear el modelo de tablas de hechos y dimensiones.
- 3) **Selección de fuentes de datos:** identificar dónde están los datos originales.
- 4) **Diseño de tablas de hechos y dimensiones:** definir estructuras físicas.
- 5) **Desarrollo ETL:** construir los flujos de extracción, transformación y carga.
- 6) **Generación de informes y consultas:** desarrollar dashboards y reportes.
- 7) **Implementación y despliegue:** poner en producción la solución.
- 8) **Evolución continua:** mantener y mejorar el sistema según cambian las necesidades.

Por qué elegimos Kimball: Su enfoque es más ágil, fácil de entender para los usuarios no técnicos y se adapta mejor a proyectos con recursos limitados. Además, permite obtener resultados rápidos a través de Data Marts específicos.

En los capítulos siguientes, seguiremos cada uno de estos pasos, desde la identificación de los requerimientos de la Red de Salud Leoncio Prado hasta la construcción de los dashboards en Power BI.

Nota final del capítulo: Los conceptos aquí explicados serán aplicados paso a paso en los siguientes capítulos. El lector notará que, aunque la teoría es importante, la clave del éxito radica en una correcta implementación adaptada a la realidad de cada organización de salud.



CAPÍTULO 3: Contexto del estudio: la Red de Salud Leoncio Prado



Para comprender la magnitud del problema y la relevancia de la solución propuesta, es necesario conocer el escenario donde se llevó a cabo esta investigación. Este capítulo describe la Red de Salud Leoncio Prado, su ubicación, población, estructura, misión, visión, y el diagnóstico inicial del proceso de toma de decisiones antes de implementar la Inteligencia de Negocios.

3.1 Ubicación, población y estructura asistencial

La Red de Salud Leoncio Prado es una institución pública peruana que forma parte del sistema de salud del Ministerio de Salud (MINSA). Su sede principal se encuentra en la provincia de Leoncio Prado, en la región Huánuco, en la zona centro-oriental del Perú.

Ubicación geográfica:

- Región: Huánuco
- Provincia: Leoncio Prado
- Capital: Tingo María
- Acceso: Carretera Central, a aproximadamente 8 horas de Lima.

Población atendida:

La red tiene jurisdicción sobre una población estimada en más de 200,000 habitantes, distribuidos principalmente en zonas urbanas y rurales de la selva alta. Esta población incluye comunidades nativas, agricultores, comerciantes y pobladores urbanos, con características socioeconómicas diversas y desafíos particulares en salud, como enfermedades tropicales, desnutrición infantil y brotes epidémicos.

Estructura asistencial:

La Red de Salud Leoncio Prado está compuesta por aproximadamente 30 establecimientos de salud entre:

- Hospitales de referencia (como el Hospital de Tingo María)
- Centros de salud (con internamiento y sin internamiento)
- Puestos de salud (atención primaria en zonas rurales)
- Postas médicas

Estos establecimientos generan diariamente una enorme cantidad de datos: consultas externas, hospitalizaciones, emergencias, partos, vacunaciones, control de crecimiento y desarrollo (CRED), etc. Sin embargo, antes de este proyecto, dichos datos no estaban integrados ni disponibles oportunamente para la toma de decisiones.

3.2 Misión, visión y objetivos estratégicos

La investigación original incluye la misión, visión y objetivos estratégicos de la Red de Salud Leoncio Prado (Inocente Eugenio, 2024). A continuación se presentan, adaptados a un lenguaje claro.

Misión

“Somos una institución que brinda servicios de salud integral con calidad, priorizando la promoción de la salud en articulación con las instituciones

representativas y comunidades organizadas, garantizando el acceso universal a la salud.”

En términos sencillos: la red se compromete a ofrecer atención médica completa y de buena calidad, trabajando de la mano con la comunidad y asegurando que nadie se quede sin atención.

Visión

“En 2024, la Red de Salud Leoncio Prado es una institución que lidera en su jurisdicción el desarrollo social local, basado en las coordinaciones de políticas sociales, garantizando la atención integral de la salud con calidad, inclusión e interculturalidad, con recursos que generan valor público para el cumplimiento de los lineamientos de políticas y objetivos nacionales y regionales.”

Es decir, aspira a ser líder en desarrollo social, con atención inclusiva y respetuosa de la diversidad cultural, utilizando eficientemente los recursos públicos.

Objetivos estratégicos (selección)

Entre los objetivos más relevantes para este manuscrito destacan:

- Reducir significativamente la morbilidad y mortalidad por enfermedades transmisibles y no transmisibles.
- Reducir la mortalidad materno infantil.
- Reducir la prevalencia de la desnutrición infantil.

- Incrementar el acceso y uso racional de medicamentos.
- Incrementar la capacidad de gestión administrativa y la capacidad resolutoria de las entidades del sector.

Todos estos objetivos dependen críticamente de la información oportuna y confiable para tomar decisiones sobre asignación de recursos, priorización de intervenciones y evaluación de resultados.

3.3 Diagnóstico inicial: ¿cómo se tomaban las decisiones antes de la BI?

Antes de la implementación de la solución de Inteligencia de Negocios, el proceso de toma de decisiones en la Red de Salud Leoncio Prado presentaba serias deficiencias. Los autores de la investigación realizaron una observación directa y sistemática, registrando indicadores clave.

Flujo de información tradicional

Los datos se generaban en cada establecimiento de salud, principalmente en sistemas administrativos y clínicos separados (algunos en papel, otros en archivos de Excel, otros en sistemas Legacy). El personal de estadística debía:

- 1) Solicitar los reportes a cada centro.
- 2) Consolidar manualmente la información en hojas de cálculo.
- 3) Verificar la consistencia (tarea tediosa debido a datos faltantes o errores).

- 4) Preparar un informe en formato Word o PDF.
- 5) Entregar el informe a la gerencia.

Este proceso tomaba, en promedio, más de tres horas para un solo reporte. Además, debido a la carga laboral, solo se podían generar 30 reportes al día en toda la red.

Herramientas utilizadas

- Microsoft Excel (principal herramienta)
- Sistemas administrativos básicos (sin integración)
- Comunicación por correo electrónico y teléfono

No existía un Data Warehouse ni herramientas de BI. Los directivos dependían completamente de la capacidad del personal de estadística para generar reportes a pedido, lo que generaba cuellos de botella.

Percepción de los usuarios

Se aplicó una encuesta para medir el nivel de satisfacción de los usuarios (directivos y jefes de área) con respecto al proceso de toma de decisiones. Los resultados iniciales (pre-prueba) mostraron:

- Bajo: 30% de los usuarios (insatisfechos)
- Medio: 40% de los usuarios
- Alto: solo el 30% de los usuarios calificaban como alto su nivel de satisfacción.

Esto reflejaba un escenario crítico, donde la mayoría de los decisores no confiaban plenamente en la información recibida o la consideraban insuficiente.

3.4 Identificación de los problemas específicos (tiempos, volumen, análisis, satisfacción)

A partir de la observación directa y la recolección sistemática de datos, se identificaron cuatro problemas específicos que afectaban directamente el proceso de toma de decisiones. Estos problemas se convirtieron en los indicadores clave para medir la mejora tras la implementación de la BI.

Problema 1: Tiempo de generación de reportes (I_1)

- **Situación inicial:** se requería un promedio de 201.78 minutos (aproximadamente 3 horas y 22 minutos) para generar un reporte solicitado.
- **Consecuencia:** los directivos tomaban decisiones con información desactualizada o, en muchos casos, decidían sin datos suficientes, basándose en la intuición.

Problema 2: Cantidad de reportes generados por día (I_2)

- **Situación inicial:** el personal de estadística solo lograba generar 29.84 reportes al día en promedio.

- **Consecuencia:** muchas solicitudes de información quedaban sin atender o se postergaban varios días, limitando el monitoreo continuo de indicadores sanitarios.

Problema 3: Tiempo para analizar la información (I₃)

- **Situación inicial:** una vez que el reporte estaba listo, los directivos necesitaban 57.82 minutos en promedio para analizarlo y extraer conclusiones útiles. Esto se debía a que los reportes eran tablas extensas, sin visualizaciones, y a menudo requerían cálculos adicionales.
- **Consecuencia:** el ciclo completo (solicitud → reporte → análisis) podía tomar casi medio día, imposibilitando respuestas ágiles ante emergencias o cambios en la demanda.

Problema 4: Nivel de satisfacción del usuario (I₄)

- **Situación inicial:** como se mencionó, solo el 30% de los usuarios calificaba el proceso como “alto”, mientras que el 30% lo calificaba como “bajo” y el 40% como “medio”.
- **Consecuencia:** desmotivación del personal, desconfianza en los datos, y una sensación general de que el sistema de información no apoyaba realmente la gestión.


Resumen del diagnóstico

Indicador	Valor inicial (pre-prueba)	Unidad
Tiempo de generación de reportes	201.78	minutos
Cantidad de reportes por día	29.84	reportes/día
Tiempo para analizar información	57.82	minutos
Nivel de satisfacción (alto)	30%	porcentaje

**Basado en (Inocente Eugenio, 2024)*



CAPÍTULO 4: Diseño metodológico para evaluar la mejora



Para que un proyecto de mejora sea creíble, no basta con decir “las cosas mejoraron”. Es necesario medir, comparar y demostrar estadísticamente que los cambios observados se deben a la intervención realizada y no al azar o a otros factores. En este capítulo explicamos cómo diseñamos la investigación para evaluar el impacto de la solución de Inteligencia de Negocios en la toma de decisiones de la Red de Salud Leoncio Prado.

4.1 Enfoque cuasi-experimental y diseño pre-prueba / post-prueba

El enfoque de nuestra investigación es cuantitativo y el diseño es cuasi-experimental. ¿Qué significa esto?

En un experimento “puro” se requiere:

- Manipular intencionalmente una variable independiente (en nuestro caso, la implementación de la solución de Business Intelligence).
- Medir el efecto sobre una variable dependiente (el proceso de toma de decisiones).
- Controlar rigurosamente todas las demás condiciones, incluyendo la asignación aleatoria de los participantes a grupos de control y experimentales.

Sin embargo, en entornos organizacionales reales, como una red de salud, no es posible asignar aleatoriamente a los directivos o procesos a grupos de control. Por ello, utilizamos un diseño cuasi-experimental que se ajusta a las condiciones del mundo real, manteniendo la validez suficiente para extraer conclusiones confiables.

El diseño específico fue pre-prueba / post-prueba con un solo grupo. Esto significa que medimos los indicadores antes de implementar la solución de BI (pre-prueba) y después (post-prueba), en el mismo grupo de procesos de toma de decisiones.

Representación del diseño:

```
G1 : O1  --  (sin estímulo)
G2 : O2  X  O3
```

**Basado en (Inocente Eugenio, 2024)*

Donde:

- G1: Grupo de referencia (no recibe intervención, solo se mide O1).
- G2: Grupo experimental (recibe la intervención X: solución de BI).
- O1: Medición pre-prueba (antes de la intervención).
- O2: Medición pre-prueba para el grupo experimental (equivalente a O1).
- O3: Medición post-prueba (después de la intervención).

En la práctica, trabajamos con una única muestra de 50 procesos de toma de decisiones a los que se les aplicó la pre-prueba, luego la intervención (la solución de BI), y finalmente la post-prueba. Comparamos los resultados antes y después para determinar si hubo una mejora significativa.

Ventaja de este diseño: Es práctico y factible en organizaciones reales.

Limitación: No podemos controlar completamente otros factores externos, pero al ser una intervención tecnológica bien delimitada, podemos atribuir los cambios principalmente a la BI.

4.2 Población, muestra y tipo de muestreo

Población

La población de estudio estuvo conformada por todos los procesos de toma de decisiones que se realizaban en la Red de Salud Leoncio Prado. Estos incluyen decisiones sobre asignación de recursos, planificación de campañas, gestión de emergencias, control de indicadores sanitarios, etc.

Unidad muestral

Cada proceso de toma de decisiones individual fue considerado como una unidad de observación. Por ejemplo, un proceso podría ser “elaborar el reporte de anemia del último mes para decidir dónde enfocar la campaña de suplementación”.

Muestra y tamaño de la muestra

No se trabajó con toda la población (que sería muy extensa y difícil de abarcar), sino con una muestra representativa de 50 procesos de toma de decisiones. El tamaño de la muestra ($n=50$) se determinó considerando los estándares de la estadística para pruebas paramétricas y la disponibilidad de recursos.

Tipo de muestreo

Se utilizó un muestreo por conveniencia (también llamado muestreo no probabilístico intencional). Esto significa que los investigadores seleccionaron los procesos que eran más accesibles y representativos de la realidad cotidiana de la red. Si bien este tipo de muestreo no permite generalizar con la misma fuerza que un muestreo aleatorio, es ampliamente aceptado en estudios aplicados y cuasi-experimentales donde el control total no es posible. Los resultados, no obstante, fueron consistentes y estadísticamente significativos.

4.3 Variables e indicadores de la investigación

En toda investigación, se definen dos tipos de variables:

- **Variable independiente (causa):** La solución de Business Intelligence (BI). Es el estímulo que aplicamos.
- **Variable dependiente (efecto):** El proceso de toma de decisiones en la red de salud.

Para poder medir la variable dependiente, la descomponemos en dimensiones e indicadores concretos. La siguiente tabla resume los cuatro indicadores utilizados:

Indicador	Descripción	Unidad de medida	Instrumento
I ₁ : Tiempo de generación de reportes	Tiempo transcurrido desde que se solicita	Minutos	Cronómetro (ficha de registro)

Indicador	Descripción	Unidad de medida	Instrumento
	un reporte hasta que se entrega		
I₂ : Cantidad de reportes generados por día	Número de informes completados diariamente	Reportes/día	Conteo (ficha de registro)
I₃ : Tiempo para analizar la información	Tiempo que tarda el directivo en comprender y extraer conclusiones del reporte	Minutos	Cronómetro (observación directa)
I₄ : Nivel de satisfacción del usuario	Percepción subjetiva de los usuarios sobre la utilidad y rapidez del sistema	Cualitativo (Bajo, Medio, Alto)	Encuesta de satisfacción

**Basado en (Inocente Eugenio, 2024)*

Estos cuatro indicadores se midieron antes (pre-prueba) y después (post-prueba) de implementar la BI. La hipótesis era que la intervención mejoraría todos ellos: menor tiempo de generación, mayor cantidad de reportes, menor tiempo de análisis, y mayor satisfacción.

4.4 Instrumentos de recolección de datos (fichas de registro, encuestas)

Para recolectar los datos de manera sistemática, se diseñaron y validaron tres tipos de instrumentos.

Fichas de registro para indicadores cuantitativos (I_1 , I_2 , I_3)

Se elaboraron fichas de observación estructuradas donde el investigador anotaba:

- Fecha y hora de inicio de la solicitud del reporte.
- Fecha y hora de entrega del reporte (para calcular I_1).
- Número de reportes completados al final del día (I_2).
- Tiempo que el directivo dedicaba a analizar el reporte (I_3).

Estas fichas fueron aplicadas por personal capacitado, durante un período suficiente para registrar 50 procesos.

Encuesta de satisfacción para el indicador cualitativo (I_4)

Se diseñó un cuestionario de 12 preguntas con escala de Likert de 3 niveles (Alto, Medio, Bajo). Algunos ejemplos de preguntas:

- 1) “El acceso al sistema es rápido” (Alto/Medio/Bajo)
- 2) “La visualización de los componentes de los reportes es intuitiva”
- 3) “El sistema muestra información útil que apoya a la toma de decisiones estratégicas”
- 4) “El tiempo de entrega de los reportes del sistema es razonable”
- 5) “Los reportes del sistema están disponibles 24/7”
- 6) “La solución de BI muestra información de reportes de anemia, morbilidad de emergencias, IRAS, EDAS, etc.”

Cada respuesta se valoró y se consolidó en un nivel global: Bajo (puntuación baja), Medio, Alto. La encuesta se aplicó a los mismos 50 usuarios antes y después de la implementación.

Validez de los instrumentos

Los instrumentos fueron validados por juicio de expertos (metodólogos y especialistas en salud) y se realizaron pruebas piloto para ajustar la redacción y asegurar la comprensión.

4.5 Herramientas estadísticas: R Project, prueba de normalidad, t de Student

Una vez recolectados los datos, era necesario analizarlos para determinar si las diferencias entre pre-prueba y post-prueba eran estadísticamente significativas o se debían al azar.

Software utilizado

Se empleó R Project (versión 4.0 en adelante), un entorno de software libre y potente para computación estadística. El código completo de los análisis se incluye en los anexos de la investigación original (Inocente Eugenio, 2024).

Prueba de normalidad

Antes de aplicar cualquier prueba paramétrica (que asume que los datos siguen una distribución normal), se verificó si los valores de los indicadores cumplían con el supuesto de normalidad. Utilizamos la prueba de Anderson-Darling (`ad.test` en R).

Los resultados mostraron que, para todos los indicadores cuantitativos (I_1 , I_2 , I_3), el p-valor fue superior a 0.05, lo que indica que no hay evidencia para rechazar la normalidad. Es decir, los datos siguen una distribución aproximadamente normal, lo cual justifica el uso de pruebas paramétricas.

Prueba t de Student para muestras pareadas

Para comparar las medias de la pre-prueba y post-prueba en un mismo grupo, se utilizó la prueba t de Student para muestras pareadas (paired t-test). Esta prueba es adecuada cuando las observaciones están relacionadas (antes y después en los mismos sujetos).

El p-valor obtenido en cada comparación fue menor que 0.05 (nivel de significancia $\alpha = 0.05$), lo que llevó a rechazar la hipótesis nula (de que no hubo mejora) y aceptar que la intervención con BI produjo un cambio estadísticamente significativo.

Interpretación práctica: La probabilidad de que las mejoras observadas se debieran al azar es inferior al 5%. Por lo tanto, podemos afirmar con un 95% de confianza que la solución de Inteligencia de

Negocios es la causa de la optimización del proceso de toma de decisiones.

Ejemplo del código R utilizado (simplificado)

```
# Cargar datos
I1_pretest <- c(149, 189, 169, ...) # 50 valores
I1_posttest <- c(1.6, 2.16, 4.87, ...)

# Prueba de normalidad
library(nortest)
ad.test(I1_pretest) # p > 0.05 → normal
ad.test(I1_posttest) # p > 0.05 → normal

# Prueba t pareada
t.test(I1_pretest, I1_posttest, paired = TRUE, conf.level = 0.95)
```

**Basado en (Inocente Eugenio, 2024)*


Los resultados detallados de cada indicador se presentan en el Capítulo 6.

Conclusión del capítulo: El diseño metodológico descrito garantiza que los resultados que presentaremos en el Capítulo 6 sean creíbles, reproducibles y estadísticamente válidos. Cualquier lector con conocimientos básicos de estadística podría replicar los análisis y llegar a las mismas conclusiones. Ahora ya sabemos cómo medimos la mejora; en el próximo capítulo veremos qué construimos para lograrla



CAPÍTULO 5:

Construcción de la solución de Inteligencia de Negocios



Una solución de BI bien diseñada transforma datos en información estratégica para mejorar la salud de nuestra población.

Una vez definidos el problema, los indicadores y el diseño metodológico, llegó el momento de construir la solución. Este capítulo es el corazón técnico del manuscrito, pero lo hemos redactado de manera que cualquier profesional de salud o TI con conocimientos básicos pueda seguir el proceso. Explicamos paso a paso: qué necesitábamos, cómo organizamos los datos, qué herramientas usamos y cómo construimos los dashboards finales.

5.1 Requerimientos funcionales y no funcionales

Antes de escribir una sola línea de código o configurar una herramienta, es fundamental entender qué necesita el negocio (la red de salud) y cómo debe comportarse la solución. Esto se formaliza en dos tipos de requerimientos.

Requerimientos funcionales (qué debe hacer el sistema)

Son las tareas concretas que la solución debe permitir realizar. Los usuarios (directivos, jefes de área) solicitaron los siguientes reportes:

Nº	Requerimiento funcional
1	Reportes de anemia por edad y región
2	Reportes de morbilidad de emergencias por cantidad de pacientes
3	Reportes de morbilidad de infecciones respiratorias agudas (IRAS) por edad y sexo
4	Reportes de morbilidad de enfermedades diarreicas agudas (EDAS) por edad y sexo
5	Reportes de seguimiento de pacientes COVID-19 por región y cantidad de pacientes

**Basado en (Inocente Eugenio, 2024)*

Estos cinco requerimientos guiaron todo el diseño dimensional y la construcción de los dashboards.

Requerimientos no funcionales (cómo debe comportarse)

Son las cualidades de calidad que debe cumplir el sistema:

N°	Requerimiento no funcional
1	Los reportes deben poder exportarse a Excel e imprimirse.
2	El software debe responder con rapidez (consultas en segundos).
3	La información y los reportes deben estar disponibles 24/7.
4	Los gráficos deben ser entendibles, legibles y amigables.
5	Se debe poder visualizar varios gráficos simultáneamente en la misma pantalla.
6	Se debe usar como gestor de base de datos Microsoft SQL Server 2019 y Visual Studio Community (por políticas de la institución).

**Basado en (Inocente Eugenio, 2024)*

Estos requerimientos nos llevaron a elegir Power BI como herramienta de visualización, dada su capacidad de exportación, rapidez y facilidad para crear dashboards interactivos.

5.2 Modelo de datos dimensional (matriz de BUS y estrella de hechos)

Uno de los principios clave de la metodología Kimball es el modelado dimensional. En lugar de usar un modelo relacional normalizado (como en los sistemas transaccionales), se organizan los datos en tablas de hechos y tablas de dimensiones.

Matriz BUS

La matriz BUS es una herramienta de planificación que relaciona cada hecho (lo que queremos medir) con las dimensiones (el contexto de esa medida). En nuestro caso, el hecho principal es el paciente (o mejor dicho, las atenciones y eventos de salud). Las dimensiones son: Anemia, IRAS, EDAS, Emergencias, Ubigeo, Seguimiento COVID-19 y Seguimiento clínico.

La matriz BUS resultante fue:

Hecho	Medidas	Anemia	IRAS	EDAS	Emergencias	Ubigeo	Seg. COVID	Seg. Clínico
Pacientes	Cantidad, morbilidad, región, sexo, edades	X	X	X	X	X	X	X

**Basado en (Inocente Eugenio, 2024)*

Esto significa que todas las dimensiones se relacionan con el hecho paciente, permitiendo analizar cualquier combinación.

Modelo estrella (star schema)

A partir de la matriz BUS, diseñamos un modelo estrella donde una tabla central de hechos (Hecho Paciente) se conecta a múltiples tablas de dimensiones. La representación gráfica (ver Figura A adaptada de la investigación original) muestra cómo cada dimensión se une mediante

claves foráneas a la tabla de hechos. Este diseño simplifica las consultas y acelera el rendimiento.




Fig. A Start net de los hechos Paciente (Inocente Eugenio, 2024)

5.3 Diseño físico de las tablas (anemia, IRAS, EDAS, emergencias, COVID-19)

Una vez definido el modelo lógico, procedimos a crear las tablas físicas en la base de datos BILP_DATAMART (SQL Server). A continuación se muestran las tablas de dimensión más importantes (solo se incluyen los campos clave; el diseño completo está en la investigación original (Inocente Eugenio, 2024)).

Tabla Dimensión Anemia

Campo	Tipo	Descripción
id_anemia	int (PK)	Identificador único del registro
id_persona	int (FK)	Identificador del paciente
fecha_atencion	date	Fecha de atención
edad	int	Edad del paciente
sexo	char(1)	Género (M/F)
localidad	varchar(100)	Lugar de residencia
anio_nacimiento	int	Año de nacimiento

**Basado en (Inocente Eugenio, 2024)*

Tabla Dimensión IRAS (infecciones respiratorias)

Campo	Tipo	Descripción
id_morbi_ira	int (PK)	Identificador único
id_persona	int (FK)	Identificador del paciente
fecha_atencion	date	Fecha de atención
edad	int	Edad
sexo	char(1)	Género
localidad	varchar(100)	Ubicación
anio_nacimiento	int	Año de nacimiento

**Basado en (Inocente Eugenio, 2024)*

Tabla Dimensión EDAS (enfermedades diarreicas)

Estructura similar a IRAS, cambiando el nombre de la clave a id_morbi_edas.

Tabla Dimensión Emergencias

Campo	Tipo	Descripción
id_morbi_emergencias	int (PK)	Identificador único
id_persona	int (FK)	Paciente
fecha_atencion	datetime	Fecha y hora
edad	int	Edad
sexo	char(1)	Género
localidad	varchar(100)	Ubicación

**Basado en (Inocente Eugenio, 2024)*

Tabla Dimensión Seguimiento COVID-19

Campo	Tipo	Descripción
id_seg_pac_covid19	int (PK)	Identificador
id_persona	int (FK)	Paciente
fecha_seguimiento	date	Fecha
estado	varchar(25)	Estado clínico
hospitalizacion	varchar(25)	Requirió hospitalización

Campo	Tipo	Descripción
con_oxigeno	varchar(25)	Requirió oxígeno
con_ventilacion	varchar(25)	Requirió ventilación

**Basado en (Inocente Eugenio, 2024)*

Tabla Hecho Paciente

Esta tabla central integra todas las dimensiones mediante claves foráneas e incluye medidas (cantidades):

```
CREATE TABLE tb_paciente (
    id_paciente varchar(10) PRIMARY KEY,
    id_ubigeo varchar(10) FOREIGN KEY REFERENCES tb_ubigeo,
    id_morbi_eda varchar(10) FOREIGN KEY REFERENCES tb_morbi_edas,
    id_morbi_ira varchar(10) FOREIGN KEY REFERENCES tb_morbi_iras,
    id_anemia varchar(10) FOREIGN KEY REFERENCES tb_anemia,
    id_atepac_covid19 varchar(10) FOREIGN KEY REFERENCES tb_atepac_covid19,
    id_seg_pac_covid19 varchar(10) FOREIGN KEY REFERENCES tb_seg_pac_covid19,
    id_morbi_emergencias varchar(10) FOREIGN KEY REFERENCES tb_morbi_emergencias,
    id_seguimiento_clinico_f300 varchar(10) FOREIGN KEY REFERENCES tb_seguimiento_clinico_f300,
    Quantity_personas_anemias int,
    Quantity_personas_morbi_edas int,
    Quantity_personas_morbi_iras int,
    Quantity_personas_morbi_emergen int
);
```

**Basado en (Inocente Eugenio, 2024)*

Las claves foráneas garantizan la integridad referencial.

5.4 Arquitectura de la solución (SQL Server, Visual Studio, SSIS)

La arquitectura física de la solución se compone de tres capas:

- 1) **Fuentes de datos:** Bases de datos transaccionales de la red de salud (cada establecimiento cuenta con su propio sistema). Estos datos están en SQL Server y, en algunos casos, en archivos planos.
- 2) **Procesamiento ETL:** Se utiliza Visual Studio Community con SQL Server Integration Services (SSIS) para extraer, transformar y cargar los datos.
- 3) **Almacenamiento analítico:** El Data Mart (BILP_DATAMART) en SQL Server 2019 alberga las tablas dimensionales y de hechos.
- 4) **Capa de análisis y visualización:** Se construye un cubo OLAP con SQL Server Analysis Services (SSAS), que luego se conecta a Power BI Desktop para generar los dashboards.

El diagrama de arquitectura (ver figura B) muestra el flujo: fuentes → ETL → Data Mart → Cubo → Power BI → usuarios.



Fig. B. Diagrama de Arquitectura basada en inteligencia de negocios (Inocente Eugenio, 2024)

5.5 Desarrollo del proceso ETL (casos prácticos)

El proceso ETL es el más laborioso pero crucial. A continuación se resume cómo se construyó, con ejemplos prácticos.

Paso 1: Crear un proyecto SSIS en Visual Studio

Desde Visual Studio Community, se creó un nuevo proyecto de tipo Integration Services. Esto genera un paquete donde se definen las tareas de flujo de datos.

Paso 2: Crear conexiones a origen y destino

Se añadieron dos conexiones ADO.NET:

- **Origen:** base de datos transaccional de la red (por ejemplo, BI_LP).
- **Destino:** Base de datos del Data Mart (BILP_DATAMART).

Paso 3: Diseñar el flujo de datos para cada dimensión

Para cada tabla de dimensión (anemia, IRAS, etc.), se creó una tarea de flujo de datos. Dentro de cada tarea:

- Se usó un origen de datos (Source Assistant) para seleccionar la tabla de origen (ej., tb_anemia).
- Se aplicaron transformaciones si era necesario: limpieza de valores nulos, conversión de tipos de datos, filtrado de registros no válidos.

- Se usó un destino de datos (Destination Assistant) para insertar los datos transformados en la tabla correspondiente del Data Mart.

Paso 4: Tarea de limpieza previa

Antes de cargar los datos, se incluyó una tarea de ejecución SQL que trunca (limpia) las tablas del Data Mart para evitar duplicados. Los comandos eran del tipo:

```
TRUNCATE TABLE tb_anemia;  
TRUNCATE TABLE tb_morbi_iras;  
-- etc.
```

Paso 5: Ejecución del paquete ETL

Una vez configuradas todas las tareas, se ejecutó el paquete. La ejecución exitosa se confirma cuando todas las tareas aparecen en verde (sin errores). En la investigación original se muestran capturas de pantalla con los flujos de datos y la confirmación de que la transacción se realizó satisfactoriamente (Inocente Eugenio, 2024).

Caso práctico (dimensión anemia): Los datos de origen tenían la edad en algunos registros como texto. Se usó una transformación “Derived Column” para convertir a entero. También se filtraron registros con fecha de atención anterior al año 2000 por considerarlos errores de carga. Esto garantizó que solo datos limpios llegaran al Data Mart.

5.6 Creación del cubo OLAP con Analysis Services

Una vez poblado el Data Mart, el siguiente paso fue crear un cubo OLAP (On-Line Analytical Processing) para permitir consultas multidimensionales rápidas.

Paso 1: Crear proyecto de Analysis Services

En Visual Studio, se creó un nuevo proyecto de tipo Analysis Services Multidimensional and Data Mining.

Paso 2: Definir la conexión al Data Mart

Se estableció una conexión a la base de datos BILP_DATAMART.

Paso 3: Crear la vista del origen de datos

Se seleccionaron todas las tablas necesarias: la tabla de hechos tb_paciente y todas las tablas de dimensión.

Paso 4: Crear las dimensiones

Para cada tabla de dimensión, se creó una dimensión en el cubo. Por ejemplo:

- Dimensión DimAnemia basada en tb_anemia.
- Dimensión DimIras basada en tb_morbi_iras.

- Dimensión DimUbigeo basada en tb_ubigeo.
- etc.

En cada dimensión se seleccionaron todos los atributos relevantes (edad, sexo, localidad, etc.) y se definieron jerarquías cuando era necesario (por ejemplo: departamento → provincia → distrito).

Paso 5: Crear el cubo

Se creó un cubo que incluye la tabla de hechos tb_paciente y todas las dimensiones. Las medidas se definieron a partir de las columnas numéricas de la tabla de hechos, como Quantity_personas_anemias, Quantity_personas_morbi_iras, etc.

Paso 6: Desplegar el cubo

Una vez configurado, se desplegó el cubo en un servidor SQL Server Analysis Services. La verificación se realizó conectándose desde SQL Server Management Studio al servidor SSAS y navegando por el cubo. Aparecieron todas las dimensiones y medidas correctamente.

5.7 Conexión a Power BI y construcción de dashboards interactivos

El último eslabón de la cadena es la visualización. Utilizamos Power BI Desktop por su facilidad de uso, potencia y bajo costo (existe versión gratuita).

Conexión al cubo

Desde Power BI Desktop:

- Seleccionamos Obtener datos → Analysis Services (cubo multidimensional).
- Ingresamos el nombre del servidor SSAS y seleccionamos el cubo que desplegamos.
- Power BI se conectó automáticamente, mostrando todas las medidas y dimensiones como campos disponibles.

Construcción de los dashboards

Siguiendo los requerimientos funcionales, se construyeron varias páginas de dashboard:

- 1) **Reporte de anemia:** Gráfico de barras de casos de anemia por edad y región, con segmentadores para filtrar por sexo.
- 2) **Reporte de IRAS:** Gráfico de líneas por semana, desglosado por edad y sexo.
- 3) **Reporte de EDAS:** Similar a IRAS.
- 4) **Reporte de emergencias:** Tabla dinámica con la cantidad de atenciones por establecimiento y diagnóstico.
- 5) **Reporte COVID-19:** Indicadores de seguimiento de pacientes, con tarjetas de resumen (recuperados, fallecidos, hospitalizados).

Se utilizaron visualizaciones como:

- Gráficos de barras apiladas
- Gráficos de líneas (series temporales)
- Mapas de calor (para distribución geográfica)
- Tarjetas (KPI)
- Segmentadores (filtros interactivos)

Los dashboards resultantes son interactivos: un usuario puede hacer clic en una barra del gráfico de anemia y automáticamente se filtran todos los demás gráficos (Inocente Eugenio, 2024). Además, se puede exportar a Excel o imprimir (requerimiento no funcional).


Validación con usuarios

Se presentaron los dashboards a un grupo piloto de directivos y jefes de área. La retroalimentación fue muy positiva: destacaron la rapidez (respuestas en segundos), la claridad de los gráficos y la posibilidad de explorar los datos por sí mismos sin depender del personal de estadística.

Nota final del capítulo: La construcción de la solución siguió fielmente la metodología de Ralph Kimball, adaptada a los recursos disponibles (herramientas Microsoft, que son estándar en muchas instituciones públicas). El lector puede replicar este mismo proceso en su propia organización, incluso con versiones gratuitas de las herramientas. En el próximo capítulo veremos los resultados concretos de esta implementación.



CAPÍTULO 6: Resultados obtenidos



Después de implementar la solución de Inteligencia de Negocios (BI) descrita en el capítulo anterior, medimos nuevamente los cuatro indicadores clave. Este capítulo presenta los resultados de forma clara y visual, demostrando que la BI transformó radicalmente la toma de decisiones en la Red de Salud Leoncio Prado.

6.1 Indicador I1: Tiempo de generación de reportes (de 202 min a 3.3 min)

El tiempo de generación de reportes se definió como los minutos transcurridos desde que un directivo solicitaba un informe hasta que el personal de estadística lo entregaba.

Resultados

Medición	Promedio (minutos)	Cambio
Pre-prueba (sin BI)	201.78 min	–
Post-prueba (con BI)	3.31 min	–98.4%

**Basado en (Inocente Eugenio, 2024)*

En términos prácticos, un reporte que antes tomaba más de 3 horas y 20 minutos ahora se genera en menos de 4 minutos. Esto representa una reducción de 198.47 minutos en promedio por cada reporte.

Distribución de los datos

De los 50 procesos observados en la post-prueba:

- El 100% de los tiempos fueron inferiores a la meta planteada (5 minutos).
- El 100% fue inferior al promedio de la pre-prueba.

Esto significa que todos los reportes después de la implementación se generaron en menos de 5 minutos, un logro notable.

¿Por qué ocurrió esta mejora?

La automatización del proceso ETL y la disponibilidad de los datos en el Data Mart eliminaron las tareas manuales de búsqueda, consolidación y limpieza. Los dashboards de Power BI permiten obtener el reporte con solo unos clics.

6.2 Indicador I2: Cantidad de reportes por día (de 30 a 63)

La cantidad de reportes generados por día mide cuántos informes completos puede producir el equipo de estadística diariamente.

Resultados

Medición	Promedio (reportes/día)	Cambio
Pre-prueba	29.84	–
Post-prueba	63.36	+112.3%

**Basado en (Inocente Eugenio, 2024)*

La productividad diaria se duplicó con creces, pasando de aproximadamente 30 a más de 63 reportes por día.

Distribución

- El 80% de los días en la post-prueba superaron la meta de 50 reportes diarios.
- El 100% superó el promedio de la pre-prueba.

Esto significa que incluso en los días de menor producción, se generaron más reportes que el promedio anterior.

Interpretación práctica

Con la misma cantidad de personal, la red de salud ahora puede atender el doble de solicitudes de información. Los directivos ya no tienen que esperar días para recibir un reporte solicitado con urgencia.

6.3 Indicador I3: Tiempo para analizar información (de 58 min a 14 min)

El tiempo para analizar la información mide cuánto tarda un directivo en comprender un reporte y extraer conclusiones útiles.

Resultados

Medición	Promedio (minutos)	Cambio
Pre-prueba	57.82 min	–
Post-prueba	14.22 min	-75.4%

**Basado en (Inocente Eugenio, 2024)*

Antes, un directivo necesitaba casi una hora para analizar un reporte. Después de la BI, solo requiere 14 minutos en promedio.

Distribución

- El 50% de los análisis en la post-prueba fueron inferiores a la meta (15 minutos).
- El 100% fue inferior al promedio de la pre-prueba.

¿A qué se debe esta mejora?

Los reportes tradicionales eran tablas extensas y sin formato visual. Los dashboards de Power BI incluyen gráficos interactivos, resúmenes automáticos y la posibilidad de filtrar dinámicamente. El directivo puede identificar rápidamente tendencias, valores atípicos y patrones sin tener que leer fila por fila.

6.4 Indicador I4: Nivel de satisfacción del usuario (incremento: 30% → 60% alto)

El nivel de satisfacción del usuario se midió mediante una encuesta de 12 preguntas con respuestas: Alto, Medio o Bajo.

Resultados de la pre-prueba (antes de la BI)

Nivel	Frecuencia	Porcentaje
Bajo	15	30%
Medio	20	40%
Alto	15	30%

**Basado en (Inocente Eugenio, 2024)*

Solo el 30% de los usuarios estaba satisfecho (nivel alto) con el proceso de toma de decisiones.

Resultados de la post-prueba (después de la BI)

Nivel	Frecuencia	Porcentaje
Bajo	0	0%
Medio	20	40%
Alto	30	60%

**Basado en (Inocente Eugenio, 2024)*

Después de la implementación:

- Ningún usuario calificó el proceso como bajo.
- El 60% lo calificó como alto (el doble que antes).
- El 40% restante lo calificó como medio.

Interpretación

La satisfacción aumentó notablemente, especialmente porque los usuarios valoraron la rapidez, la fiabilidad y la facilidad de uso de los dashboards. Durante las entrevistas posteriores, varios directivos mencionaron que “ahora sienten que los datos realmente apoyan sus decisiones”.

6.5 Prueba de normalidad y contraste de hipótesis (t de Student, $p < 0.05$)

Para asegurar que las mejoras observadas no se debieran al azar, realizamos pruebas estadísticas rigurosas.

Prueba de normalidad (Anderson-Darling)

Antes de aplicar pruebas paramétricas, verificamos si los datos de cada indicador seguían una distribución normal. Utilizamos la prueba de Anderson-Darling en R Project.

Resultados:

Indicador	P-valor (pre)	P-valor (post)	¿Normal?
I_1 (tiempo reporte)	0.5572	0.2047	Sí ($p > 0.05$)
I_2 (cantidad reportes)	0.1344	0.1943	Sí ($p > 0.05$)
I_3 (tiempo análisis)	0.0819	0.1656	Sí ($p > 0.05$)

Indicador	P-valor (pre)	P-valor (post)	¿Normal?
Total (para hipótesis general)	0.1946	0.1691	Sí ($p > 0.05$)

*Basado en (Inocente Eugenio, 2024)

Todos los p-valores fueron superiores a 0.05, lo que indica que no hay evidencia para rechazar la normalidad. Por lo tanto, podemos usar pruebas paramétricas.

Prueba t de Student para muestras pareadas

Comparamos las medias de la pre-prueba y post-prueba para cada indicador usando la prueba t pareada. La hipótesis alternativa (H_a) era que la intervención mejoraba el indicador (en la dirección esperada).

Resultados:

Indicador	Valor t	Grados de libertad	P-valor	¿Significativo?
I_1 (disminución)	33.48	49	< 0.0001	Sí
I_2 (aumento)	-13.31	49	< 0.0001	Sí
I_3 (disminución)	9.11	49	< 0.0001	Sí
Total (hipótesis general)	36.92	49	< 0.0001	Sí

*Basado en (Inocente Eugenio, 2024)

En todos los casos, el p-valor fue menor que 0.05 (de hecho, menor que 0.0001). Esto significa que la probabilidad de que las mejoras se debieran al azar es inferior al 0.01%.

Conclusión estadística

Rechazamos la hipótesis nula (de que no hubo mejora) y aceptamos la hipótesis alternativa: la implementación de la solución de Inteligencia de Negocios causó una mejora estadísticamente significativa en todos los indicadores del proceso de toma de decisiones, con un nivel de confianza del 95%.

Resumen visual de los resultados

Indicador	Pre-prueba	Post-prueba	Cambio	Significancia
Tiempo generación reportes (min)	201.78	3.31	▼ 98.4%	$p < 0.0001$
Cantidad reportes/día	29.84	63.36	▲ 112.3%	$p < 0.0001$
Tiempo análisis (min)	57.82	14.22	▼ 75.4%	$p < 0.0001$
Satisfacción (%) (alto)	30%	60%	▲ 100%	(cualitativo)

**Basado en (Inocente Eugenio, 2024)*

Conclusión del capítulo: Los números hablan por sí mismos. La Inteligencia de Negocios no solo mejoró los indicadores, sino que lo hizo de manera contundente y estadísticamente demostrable. En el siguiente capítulo discutiremos estos hallazgos a la luz de otros estudios y extraeremos lecciones aprendidas.



CAPÍTULO 7: Discusión y lecciones aprendidas



Los resultados presentados en el capítulo anterior son contundentes: la implementación de una solución de Inteligencia de Negocios mejoró drásticamente el proceso de toma de decisiones en la Red de Salud Leoncio Prado. Sin embargo, estos hallazgos no se dan en el vacío. En este capítulo comparamos nuestros resultados con los de otros estudios, identificamos los factores que explican el éxito, reconocemos las limitaciones encontradas y ofrecemos recomendaciones prácticas para futuros proyectos.

7.1 Comparación con estudios similares en el sector salud y otros sectores

La literatura sobre Business Intelligence en el ámbito sanitario ha crecido considerablemente en los últimos años. Nuestros resultados coinciden con los hallazgos de investigaciones nacionales e internacionales.

Estudios en el sector salud

(Sánchez Rodríguez, 2022) Aplicó un programa de Inteligencia de Negocios en una cooperativa de ahorro y crédito en Lima, Perú. Utilizando un diseño preexperimental, logró que el nivel de BI de los ejecutivos pasara de un nivel predominantemente bajo (50%) a un nivel alto (72,73%). Este estudio demuestra que la BI no solo mejora procesos, sino que también capacita a las personas en el uso de datos para decidir.

(Mejia Huayhua et al., 2023) Implementaron un prototipo de BI para la vigilancia de salud pública en la región de Arequipa, Perú. Su sistema permitió identificar situaciones de pandemia y evaluar la inmunidad poblacional. Aunque su enfoque fue más epidemiológico que gerencial, coincide con el nuestro en la importancia de contar con indicadores visuales y oportunos para la toma de decisiones en salud pública.

(Hidalgo et al., 2020) Construyeron un datamart para apoyar la toma de decisiones en la Unidad de Docencia del Hospital Regional

Ernesto Torres Galdames (Iquique, Chile). Siguiendo también la metodología de Kimball, lograron mejorar la disponibilidad de información sobre prácticas profesionales. Su experiencia refuerza que el enfoque dimensional es adecuado para entornos hospitalarios.

Estudios en otros sectores

(Golestanizadeh et al., 2023) Identificaron oportunidades gerenciales para aplicar BI en empresas constructoras basadas en proyectos. Concluyeron que la BI puede mejorar significativamente el desempeño de los proyectos si se implementa correctamente. Esto sugiere que los beneficios de la BI trascienden sectores y son aplicables a cualquier organización que requiera decisiones basadas en datos.

(Hartl et al., 2016) Investigaron la relación entre BI y la gestión del desempeño corporativo (CPM). Encontraron que las capacidades de calidad, suministro y análisis de datos tienen un impacto significativo en los procesos organizacionales. Nuestro estudio confirma esa relación: al mejorar la calidad y el suministro de datos (ETL, Data Mart), el desempeño en la toma de decisiones mejoró notablemente.

(Kašparová, 2022) Utilizó el modelo UTAUT2 para examinar los factores que inciden en la adopción de herramientas de BI. Descubrió que el hábito es el factor más influyente en la intención de uso y el comportamiento efectivo. En nuestra experiencia, una vez que los directivos se acostumbraron a usar los dashboards de Power BI (aproximadamente dos semanas), ya no quisieron volver al sistema anterior.

Singularidades de nuestro estudio

A diferencia de la mayoría de los estudios citados, nuestro trabajo cuantifica el impacto en indicadores concretos (tiempos, volumen, satisfacción) y lo valida con pruebas estadísticas rigurosas (t de Student). Además, se centra en una red de salud pública peruana con recursos limitados, lo que lo hace especialmente relevante para contextos similares en América Latina.

7.2 Factores críticos de éxito en la implementación de BI en salud

A partir de nuestra experiencia y de la literatura revisada, identificamos los siguientes factores críticos que explican el éxito del proyecto:

1. Seguir una metodología probada (Kimball)

Adoptar el enfoque dimensional de Ralph Kimball nos permitió avanzar de manera ordenada, desde los requerimientos del negocio hasta la implementación técnica. La metodología es ágil y permite obtener resultados rápidos (Data Marts específicos) sin necesidad de esperar a tener un Data Warehouse corporativo completo.

2. Involucrar a los usuarios desde el inicio

Los requerimientos funcionales y no funcionales se definieron con la participación activa de los directivos y jefes de área. Esto garantizó que la solución respondiera a necesidades reales y no a supuestos técnicos. Además, facilitó la adopción posterior.

3. Elegir herramientas adecuadas al contexto

Optamos por Microsoft Power BI y SQL Server porque son herramientas ampliamente difundidas, con versiones gratuitas o de bajo costo, y con gran cantidad de documentación y comunidad de soporte. Power BI, además, ha sido reconocido por (Gartner, 2025) como el líder del cuadrante mágico por decimosexto año consecutivo.

4. Automatizar el proceso ETL

La automatización de la extracción, transformación y carga de datos eliminó la dependencia de tareas manuales propensas a errores. Esto no solo aceleró la generación de reportes, sino que también mejoró la confiabilidad de los datos.

5. Capacitación y acompañamiento

Se realizaron sesiones de capacitación breves pero prácticas para los usuarios finales. Se les enseñó a navegar por los dashboards, aplicar

filtros y exportar datos. El acompañamiento inicial fue clave para superar la resistencia al cambio.

6. Compromiso de la alta dirección

El proyecto contó con el respaldo explícito de los directivos de la red de salud, quienes promovieron el uso de la solución y dieron el ejemplo al solicitar sus reportes exclusivamente a través de los dashboards.

7.3 Limitaciones encontradas (calidad de datos, capacitación del personal)

A pesar del éxito, enfrentamos varias limitaciones que es importante reconocer para que otros proyectos las tengan en cuenta.

Calidad de datos inicial

Los datos de origen presentaban problemas comunes en sistemas de salud pública:

- **Datos faltantes:** Muchos registros tenían campos vacíos (edad, sexo, ubicación).
- **Inconsistencias:** La misma entidad (por ejemplo, un distrito) podía estar escrita de diferentes maneras.
- **Duplicación:** Pacientes registrados múltiples veces con ligeras variaciones en sus nombres.

Solución adoptada: Durante el proceso ETL, implementamos reglas de limpieza: estandarización de textos, imputación de valores faltantes cuando era posible (p. ej., edad calculada a partir de la fecha de nacimiento) y eliminación de duplicados mediante coincidencia de múltiples campos. Sin embargo, la calidad de datos ideal requeriría intervenciones en los sistemas de origen.

Capacitación limitada del personal

El personal de estadística y los directivos tenían distintos niveles de alfabetización digital. Algunos mostraban resistencia a adoptar una nueva herramienta. Las sesiones de capacitación fueron breves (2-3 horas) debido a las limitaciones de tiempo, lo que pudo ser insuficiente para algunos usuarios.

Solución adoptada: Se crearon guías rápidas impresas (una página) con los pasos básicos. Además, se designó a un “campeón de BI” (un usuario avanzado) para resolver dudas cotidianas.

Infraestructura tecnológica limitada

La red de salud no contaba con servidores dedicados de alta capacidad. Utilizamos equipos existentes, lo que en ocasiones generó lentitud en las consultas masivas. Para mitigarlo, optimizamos las consultas MDX (lenguaje de cubos) y programamos el refresco de datos en horarios de bajo uso (madrugada).

Resistencia al cambio

Algunos miembros del personal de estadística vieron la automatización como una amenaza a sus puestos de trabajo. Fue necesario explicar que la BI no reemplaza a las personas, sino que las libera de tareas repetitivas para que puedan dedicarse a análisis más profundos y estratégicos.

7.4 Recomendaciones para futuros proyectos

Basados en nuestra experiencia y en las lecciones aprendidas, ofrecemos las siguientes recomendaciones para quienes deseen implementar soluciones de BI en el sector salud u otras organizaciones:

Recomendación 1: Empiece con un proyecto piloto

No intente abarcar toda la organización desde el principio. Elija un área o conjunto de indicadores acotado (por ejemplo, reportes de anemia y emergencias) y desarrolle una solución completa. Una vez demostrado el valor, expanda a otras áreas.

Recomendación 2: Invierta en la calidad de los datos desde el origen

Cuanto más limpios sean los datos en las fuentes originales, menos trabajo costará el ETL. Implemente validaciones en los sistemas transaccionales (por ejemplo, campos obligatorios, listas desplegables en lugar de texto libre).

Recomendación 3: Capacite antes y después

Realice sesiones de capacitación previas a la implementación (para generar expectativas) y posteriores (para reforzar). Ofrezca materiales de apoyo simples y accesibles. Considere la posibilidad de certificar a “superusuarios” que puedan ayudar a sus compañeros.

Recomendación 4: Involucre a los usuarios en el diseño de dashboards

No diseñe los dashboards solo con criterios técnicos. Muestre prototipos a los usuarios y pida retroalimentación. Un gráfico puede ser estadísticamente correcto pero inútil si el usuario no lo entiende.

Recomendación 5: Mida el impacto

Defina indicadores claros antes de empezar (como hicimos nosotros) y vuelva a medirlos después de la implementación. Esto permitirá cuantificar el retorno de la inversión y justificar futuros proyectos.

Recomendación 6: Planifique la sostenibilidad

Una solución de BI no es un proyecto que termina, sino un sistema que debe mantenerse. Asigne recursos para:

- Actualización periódica de los procesos ETL cuando cambien las fuentes.

- Refresco de datos (frecuencia diaria o semanal).
- Soporte a usuarios (mesa de ayuda).
- Evolución de los dashboards según nuevas necesidades.

Recomendación 7: Considere la analítica predictiva como siguiente paso

Una vez consolidada la BI descriptiva (qué pasó), el siguiente nivel es la analítica predictiva (qué podría pasar). Utilizando técnicas de minería de datos y machine learning, se pueden predecir brotes epidemiológicos, demanda de camas UCI o riesgos de deserción de tratamientos. Herramientas como R, Python o los módulos de machine learning de Power BI (Power BI Premium) permiten explorar este camino.

Conclusión del capítulo: Los resultados obtenidos en la Red de Salud Leoncio Prado son sólidos y comparables a los mejores estándares nacionales e internacionales. Los factores críticos de éxito identificados pueden servir de orientación para otras organizaciones. Reconocer las limitaciones no debilita el estudio, sino que lo fortalece, porque permite a futuros investigadores y profesionales evitar obstáculos similares. En el último capítulo presentaremos las conclusiones finales y las recomendaciones para los gestores de salud.

CAPÍTULO 8:

Conclusiones y recomendaciones para gestores del sector salud



Hemos recorrido un largo camino. Desde el diagnóstico de los problemas en la toma de decisiones de la Red de Salud Leoncio Prado, pasando por los fundamentos de la Inteligencia de Negocios, el diseño e implementación de la solución, hasta la discusión de los resultados. Llegó el momento de sintetizar los hallazgos, extraer lecciones prácticas y mirar hacia el futuro.

8.1 Síntesis de los hallazgos

La implementación de la solución de Inteligencia de Negocios (BI) en la Red de Salud Leoncio Prado ha demostrado, con evidencia cuantitativa y cualitativa, que es posible optimizar radicalmente el proceso de toma de decisiones en una organización sanitaria pública.

Los principales hallazgos se resumen en la siguiente tabla:

Indicador	Situación inicial (pre-prueba)	Situación final (post-prueba)	Mejora
Tiempo de generación de reportes	202 minutos	3.3 minutos	▼ 98.4%
Cantidad de reportes por día	30 reportes	63 reportes	▲ 112%
Tiempo para analizar información	58 minutos	14 minutos	▼ 75.4%
Satisfacción del usuario (nivel alto)	30%	60%	▲ 100%

**Basado en (Inocente Eugenio, 2024)*

Estas mejoras fueron estadísticamente significativas ($p < 0.0001$), lo que significa que la probabilidad de que se deban al azar es inferior al 0.01%. Por lo tanto, podemos afirmar con un 95% de confianza que la solución de BI es la causa directa de la optimización.

Más allá de los números, este proyecto demostró que:

- 1) **La metodología de Ralph Kimball** es adecuada y eficaz para entornos de salud pública, permitiendo construir soluciones escalables con recursos limitados.
- 2) **La automatización del proceso ETL** elimina la dependencia de tareas manuales, reduce errores y libera al personal para actividades de mayor valor.
- 3) **Las herramientas de visualización como Power BI** hacen que los datos sean comprensibles para los decisores, acortando drásticamente el tiempo de análisis.
- 4) **La satisfacción de los usuarios** se multiplica cuando la información es oportuna, confiable y fácil de usar, lo que a su vez fomenta una cultura de decisión basada en datos.

8.2 Recomendaciones prácticas: capacitar, estandarizar fuentes, mantener el sistema

Para los gestores de salud que deseen emprender proyectos similares, ofrecemos las siguientes recomendaciones prácticas, organizadas en tres ejes fundamentales.

Capacitar: el factor humano es clave

- **Capacite a los usuarios finales** (directivos, jefes de área) en el uso de los dashboards. No asuma que sabrán usarlos solo porque son “intuitivos”. Realice talleres prácticos de 2 horas, centrados en casos reales.

- **Capacite al personal técnico** (estadística, TI) en los conceptos de BI, ETL y modelado dimensional. Considere certificaciones gratuitas en línea (Microsoft Learn, Coursera).
- **Cree una red de “campeones de BI”** dentro de la organización: usuarios avanzados que puedan ayudar a sus compañeros y actuar como enlace con el equipo técnico.
- **Comunique el propósito:** explique que la BI no reemplaza puestos de trabajo, sino que los transforma, permitiendo dedicarse a tareas más analíticas y menos repetitivas.

Estandarizar fuentes: la calidad de datos empieza en el origen

- **Implemente validaciones en los sistemas transaccionales.** Por ejemplo, que el campo “sexo” solo acepte M/F, que la “fecha de nacimiento” sea obligatoria, que los códigos de diagnóstico sigan un estándar (CIE-10).
- **Utilice catálogos maestros (master data management)** para entidades comunes como pacientes, establecimientos de salud y ubicaciones geográficas. Así, un mismo paciente no aparecerá con diferentes nombres en distintos sistemas.
- **Establezca un proceso de limpieza periódica** de los datos históricos. Antes del ETL, realice un análisis de calidad para identificar y corregir problemas sistemáticos.
- **Documente las fuentes y las transformaciones.** Mantenga un registro claro de qué significa cada campo, de dónde proviene y qué reglas de transformación se le aplican.

Mantener el sistema: la sostenibilidad es fundamental

- **Asigne un presupuesto anual para el mantenimiento** de la solución (servidores, licencias, horas de personal). Un proyecto de BI no es un gasto único, sino una inversión continua.
- **Programe el refresco de datos** de manera automática y periódica (diaria, semanal). Los dashboards deben mostrar información actualizada, o perderán utilidad.
- **Establezca un canal de soporte** para reportar incidencias y solicitar mejoras (puede ser un correo electrónico o una reunión semanal).
- **Revise periódicamente los requerimientos.** Las necesidades de información cambian. Cada seis meses, reúnanse con los usuarios para ajustar o añadir nuevos indicadores.
- **Audite el uso de los dashboards.** Mida qué reportes son los más consultados y cuáles no se usan. Elimine lo que no aporta valor y refuerce lo que sí.

8.3 Próximos pasos: hacia la analítica predictiva y la inteligencia artificial

La solución implementada en este manuscrito corresponde al nivel descriptivo de la Inteligencia de Negocios: responde a la pregunta “¿qué pasó?” (por ejemplo, “¿cuántos casos de anemia hubo el mes pasado?”). Sin embargo, el potencial de los datos va mucho más allá. Los siguientes pasos naturales son la analítica predictiva (¿qué podría pasar?) y la analítica prescriptiva (¿qué debemos hacer?).

Analítica predictiva: prever antes de que ocurra

Utilizando técnicas de minería de datos y machine learning, se pueden construir modelos que predicen eventos futuros basados en patrones históricos. Algunas aplicaciones concretas en salud:

- **Predicción de brotes epidémicos:** usando datos históricos de IRAS, EDAS y variables ambientales, se puede anticipar un brote con días o semanas de antelación, permitiendo activar campañas preventivas.
- **Predicción de ocupación de camas UCI:** basada en la evolución de casos de COVID-19 o de otras enfermedades críticas, se puede estimar la demanda futura y reasignar recursos.
- **Detección temprana de deserción de tratamientos:** identificando patrones de inasistencia a citas de control (por ejemplo, en pacientes con tuberculosis o VIH), se puede intervenir antes de que abandonen el tratamiento.
- **Riesgo de mortalidad intrahospitalaria:** modelos que combinan edad, comorbilidades, signos vitales y resultados de laboratorio para estimar el riesgo de cada paciente.

Herramientas como R, Python (con librerías scikit-learn, TensorFlow) o los módulos de machine learning de Power BI Premium y Azure Machine Learning permiten implementar estos modelos.

Analítica prescriptiva y sistemas de apoyo a la decisión

El nivel más avanzado es la analítica prescriptiva, que no solo predice, sino que recomienda acciones optimizadas. Por ejemplo:

- **Asignación óptima de personal:** dado un volumen esperado de consultas y la disponibilidad de médicos, ¿cómo se deben programar los turnos para minimizar el tiempo de espera?
- **Rutas de vacunación más eficientes:** considerando la ubicación de los puestos de salud y la población objetivo, ¿cuál es la ruta que maximiza la cobertura con el menor costo logístico?
- **Protocolos clínicos adaptativos:** con base en las características del paciente, ¿qué tratamiento tiene mayor probabilidad de éxito?

Estos sistemas suelen combinar BI, inteligencia artificial y teoría de optimización.

Recomendaciones para avanzar

- 1) **Consolide primero la BI descriptiva.** No salte a la analítica predictiva sin tener una base sólida de datos limpios y dashboards confiables.
- 2) **Forme un equipo multidisciplinario:** incluya profesionales de salud (que entiendan el dominio), analistas de datos (que sepan modelado) y personal de TI (que implemente).
- 3) **Empiece con un proyecto piloto predictivo acotado.** Por ejemplo, predecir la demanda de consultas externas en el hospital principal para la próxima semana. Mida la precisión y ajuste el modelo.

- 4) **Capacite al personal en conceptos básicos de machine learning** (no necesariamente programación, sino interpretación de resultados). Un modelo predictivo es inútil si los médicos o gestores no confían en él.
- 5) **Asegure la ética y la privacidad.** Los datos de salud son sensibles. Cualquier modelo predictivo debe respetar la confidencialidad del paciente y no generar sesgos injustos.

Visión a largo plazo: hacia una salud digital integrada

La Inteligencia de Negocios, la analítica predictiva y la inteligencia artificial son peldaños hacia una salud digital integrada, donde todos los sistemas (historias clínicas electrónicas, laboratorio, farmacia, admisión) compartan datos en tiempo real, y donde los gestores y clínicos dispongan de información y recomendaciones en el momento preciso de la decisión.

Esta investigación ha demostrado que el primer peldaño de la BI descriptiva no solo es posible, sino que genera un retorno inmediato en eficiencia y satisfacción. El camino continúa. Invitamos a los gestores del sector salud a dar el primer paso.

BIBLIOGRAFÍA

- Ain, N. U., Vaia, G., DeLone, W. H., & Waheed, M. (2019). Two decades of research on business intelligence system adoption, utilization and success – A systematic literature review. *Decision Support Systems*, 125, 113113. <https://doi.org/10.1016/J.DSS.2019.113113>
- Alnoukari, M., Alhawasli, H. A., Alnafea, H. A., & Zamreek, A. J. (2012). Business Intelligence: Body of Knowledge. *Https://Services.Igi-Global.Com/Resolvedoi/Resolve.Aspx?Doi=10.4018/978-1-61350-050-7.Ch001*, 1–13. <https://doi.org/10.4018/978-1-61350-050-7.CH001>
- Davenport, & H., T. (2010). Business Intelligence and Organizational Decisions. *Https://Services.Igi-Global.Com/Resolvedoi/Resolve.Aspx?Doi=10.4018/Jbir.2010071701*, 1, 1–12. <https://doi.org/10.4018/JBIR.2010071701>
- Diario Gestión. (2014, April). *Gobierna tu información y aplícala a tu negocio con Business Intelligence*. <https://gestion.pe/tendencias/gobierna-informacion-aplicala-negocio-business-intelligence-57744-noticia/>
- Gartner. (2025, June). *Gartner Magic Quadrant for Analytics and Business Intelligence Platforms*. <https://www.gartner.com/en/documents/6576602>
- Golestanizadeh, M., Sarvari, H., Chan, D. W. M., Banaitienė, N., & Banaitis, A. (2023). Managerial opportunities in application of business intelligence in construction companies. *Journal of Civil Engineering and Management*, 29(6), 487–500. <https://doi.org/10.3846/JCEM.2023.19533>
- Hartl, K., Jacob, O., Mbep, F. L., Budree, A., & Fourie, L. (2016). The impact of business intelligence on corporate performance management. *Proceedings of the Annual Hawaii International Conference on System Sciences*, 2016-March, 5042–5051. <https://doi.org/10.1109/HICSS.2016.625>
- Herbert A. Simon. (1979). *Rational Decision Making in Business Organizations on JSTOR*. <https://www.jstor.org/stable/1808698>
- Hidalgo, J. O., Pinto, R. V., & Ramírez, J. D. (2020). Elementos de inteligencia de negocios para el apoyo de toma de decisiones en la unidad de docencia del hospital regional ernesto torres galdames. *RISTI - Revista Iberica de Sistemas e Tecnologias de Informacao*, 2020(E31), 357–371.

<https://investigadores.uta.cl/en/publications/elementos-de-inteligencia-de-negocios-para-el-apoyo-de-toma-de-de/>

Inmon, W. H. . (2005). *Building the data warehouse*. 500.

Inocente Eugenio, O. (2024). *Solución de inteligencia de negocios, para el proceso de toma de decisiones en la red de salud de Leoncio Prado*. Universidad Nacional Agraria de la Selva. <https://hdl.handle.net/20.500.14292/2751>

Kašparová, P. (2022). Intention to use business intelligence tools in decision making processes: applying a UTAUT 2 model. *Central European Journal of Operations Research* 2022 31:3, 31(3), 991–1008. <https://doi.org/10.1007/S10100-022-00827-Z>

Kimball, R., & Ross, M. (2013). *The Data Warehouse Toolkit, 3rd Edition - Kimball Group*. <https://www.kimballgroup.com/data-warehouse-business-intelligence-resources/books/data-warehouse-dw-toolkit/>

Kimball, Ralph. (1996). The Data Warehouse Toolkit: Practical Techniques for Building Dimensional Data Warehouses 2nd Editoin. *Library Journal*, 121(13), 374. https://books.google.com/books/about/The_Data_Warehouse_Toolkit.html?hl=es&id=VlBqcgAACAAJ

Kurniawan, D., Saputra, A., Sanjaya, M. R., & Yamani, Z. (2021). Extending the Understanding of Business Intelligence and Its Application in Startups. *Proceedings of the 4th Forum in Research, Science, and Technology (FIRST-T1-T2-2020)*, 7, 550–556. <https://doi.org/10.2991/AHE.K.210205.092>

Laudon, K. C., & Laudon, J. P. (2004). *Management Information Systems: Managing the Digital Firm*. https://books.google.com.pe/books?hl=es&lr=&id=KD8ZZ66PF-gC&oi=fnd&pg=PA6&ots=hnopucpS3C&sig=MhC4ZqADIXS9n80KPeC6wKFduLw&redir_esc=y#v=onepage&q&f=false

Mejia Huayhua, J. C., Mestas Escarcena, C. A., & Silva Fernández, J. M. (2023). Global Public Health Surveillance prototype for decision making: Prototipo de Vigilancia Global de Salud Pública con proceso de Inteligencia de Negocios. *TECHNO REVIEW. International Technology, Science and Society*

Review /Revista Internacional De Tecnología, Ciencia Y Sociedad.
<https://doi.org/10.37467/revtechno.v13.4802>

Sánchez Rodríguez, L. Z. (2022). *Inteligencia de negocios aplicada a los ejecutivos de una Cooperativa de Ahorro y Crédito de Lima Cercado.*

Turban, E., Sharda, R., & Delen, D. (2019). *Business Intelligence e Análise de Dados para Gestão do Negócio - 4.ed.*
[https://books.google.com.pe/books?hl=es&lr=&id=Qr6xDwAAQBAJ&oi=fnd&pg=PR1&dq=Turban,+E.,+Delen,+D.,+%26+Sharda,+R.+\(2019\).+Business+Intelligence,+Analytics,+and+Data+Science:+A+Managerial+Perspective+\(4th+ed.\)&ots=eb6fwF32O-&sig=jtB1Csq_lfDc7kfhLQClJ6bb9no&redir_esc=y#v=onepage&q&f=false](https://books.google.com.pe/books?hl=es&lr=&id=Qr6xDwAAQBAJ&oi=fnd&pg=PR1&dq=Turban,+E.,+Delen,+D.,+%26+Sharda,+R.+(2019).+Business+Intelligence,+Analytics,+and+Data+Science:+A+Managerial+Perspective+(4th+ed.)&ots=eb6fwF32O-&sig=jtB1Csq_lfDc7kfhLQClJ6bb9no&redir_esc=y#v=onepage&q&f=false)

World Health Organization (WHO). (2021). *Global strategy on digital health 2020-2025.* <http://apps.who.int/bookorders>.



Dirección legal: Urb. Paseo del Mar
Nuevo Chimbote, Santa, Ancash
Correo electrónico: ed.honexus@gmail.com
Teléfono: 978653152



ISBN: 978-612-99401-3-7



9 786129 940137