

Maestría en

ADMINISTRACIÓN DE EMPRESAS

**Tesis previa a la obtención de título de
Magister en Administración de Empresas**

AUTORES:

Ing. Emilia Alejandra Torres Moscoso

Ing. Ana Gabriela Chico Vinuela

Ing. Edwin Fabian Yépez Guacapiña

PhD. Cristian David Oña Rodriguez

Ing. David Alexander Mata Caba

TUTOR: Prof. José Luis Pérez Galán

Modelo de Business Intelligence y Big Data para la
Optimización de Retención, Recurrencia y Rentabilidad
en Oña Rodríguez Ingeniería Automotriz

**PROYECTO DE TITULACIÓN – FIN DE MÁSTER
MAESTRÍA EN ADMINISTRACIÓN DE EMPRESA ENL**

Modelo de Business Intelligence y Big Data para la Optimización de Retención,
Recurrencia y Rentabilidad en Oña Rodríguez Ingeniería Automotriz

Por:

Ing. Emilia Alejandra Torres Moscoso

Ing. Ana Gabriela Chico Vinueza

Ing. Edwin Fabian Yépez Guacapiña

PhD. Cristian David Oña Rodríguez

Ing. David Alexander Mata Caba

Febrero 2026

Aprobado



Cristian Melo
Presidente(a) del Tribunal
Universidad Internacional del Ecuador

Yo, Cristian Javier Melo González e Ignacio Maroto, declaramos que, personalmente conocemos que los graduandos: **Ing.** Emilia Alejandra Torres Moscoso, **Ing.** Ana Gabriela Chico Vinuesa, **Ing.** Edwin Fabian Yépez Guacapiña, **PhD.** Cristian David Oña Rodríguez, **Ing.** David Alexander Mata Caba, son los autores exclusivos de la presente investigación y que ésta es original, auténtica y personal de ellos.



Cristian Melo
Coordinador MBA UIDE



Ignacio Maroto
Provost WBS

Autoría del Trabajo de Titulación

Nosotros: **Ing.** Emilia Alejandra Torres Moscoso, **Ing.** Ana Gabriela Chico Vinueza, **Ing.** Edwin Fabian Yépez Guacapiña, **PhD.** Cristian David Oña Rodríguez, **Ing.** David Alexander Mata Caba, declaramos bajo juramento que el trabajo de titulación titulado **Modelo de Business Intelligence y Big Data para la Optimización de Retención, Recurrencia y Rentabilidad en Oña Rodríguez Ingeniería Automotriz** es de nuestra autoría y exclusiva responsabilidad legal y académica; que no ha sido presentado anteriormente para ningún grado o calificación profesional, habiéndose citado las fuentes correspondientes y respetando las disposiciones legales que protegen los derechos de autor vigentes.



Emilia Alejandra Torres Moscoso

Correo electrónico:
emiatorresm@gmail.com




Ana Gabriela Chico Vinueza

Correo electrónico: atina-dillon26@hotmail.com



Edwin Fabian Yépez Guacapiña

Correo electrónico:
edwin_yepes@hotmail.com



Cristian David Oña Rodríguez

Correo electrónico:
crionaro@uide.edu.ec



David Alexander Mata Caba

Correo electrónico:
damatacab@uide.edu.ec

Autorización de Derechos de Propiedad Intelectual

Nosotros, **Ing.** Emilia Alejandra Torres Moscoso, **Ing.** Ana Gabriela Chico Vinueza, **Ing.** Edwin Fabian Yépez Guacapiña, **PhD.** Cristian David Oña Rodríguez, **Ing.** David Alexander Mata Caba, en calidad de autores del trabajo de investigación titulado **Modelo de Business Intelligence y Big Data para la Optimización de Retención, Recurrencia y Rentabilidad en Oña Rodríguez Ingeniería Automotriz**, autorizo a la Universidad Internacional del Ecuador (UIDE) para hacer uso de todos los contenidos que me pertenecen o de parte de los que contiene esta obra, con fines estrictamente académicos o de investigación. Los derechos que como autor me corresponden, lo establecido en los artículos 5, 6, 8, 19 y demás pertinentes de la Ley de Propiedad Intelectual y su Reglamento en Ecuador.

D. M. Quito, 19 de febrero del 2026

Emilia Alejandra Torres Moscoso

Correo electrónico:

emiatorresm@gmail.com

Ana Gabriela Chico Vinueza

Correo electrónico: [atina-](mailto:atina-dillon26@hotmail.com)

dillon26@hotmail.com

Edwin Fabian Yépez Guacapiña

Correo electrónico:

edwin_yepes@hotmail.com

Cristian David Oña Rodríguez

Correo electrónico:

crionaro@uide.edu.ec

David Alexander Mata Caba

Correo electrónico:

damatacab@uide.edu.ec

DEDICATORIA

El presente trabajo se dedica al compromiso compartido con la excelencia académica y a la convicción de que el conocimiento estratégico, aplicado con rigor y disciplina, constituye una herramienta fundamental para transformar organizaciones y generar valor sostenible en el largo plazo.

AGRADECIMIENTOS

Expresamos nuestro sincero agradecimiento al equipo docente del programa MBA por su guía académica, exigencia intelectual y acompañamiento constante durante el desarrollo de este proyecto. Sus aportes han fortalecido nuestra visión estratégica y consolidado nuestro enfoque analítico en la toma de decisiones.

Reconocemos especialmente la articulación académica entre la Universidad Internacional del Ecuador, Westfield Business School y EIG Education, cuya colaboración institucional ha permitido una formación integral con perspectiva internacional, enfoque estratégico y una visión orientada al Triple Bottom Line (TBL), integrando el equilibrio entre sostenibilidad económica, impacto social y responsabilidad ambiental.

Agradecemos también a la coordinación del programa por promover un entorno académico riguroso, estructurado y orientado a resultados, que ha sido clave para la consolidación del presente trabajo.

Att: El Equipo

INDICE DEL DOCUMENTO

Contenido

PARTE I:	15
Capitulo 1	15
1.1 Diagnóstico Estratégico y Definición del Problema	15
1.2 Definición del Problema y Objetivos Iniciales del Proyecto	15
1.2.1 Definición Estratégica del Problema	15
1.3 Enfoque BI & Big Data	16
1.4 Objetivos Iniciales del Proyecto	17
1.5 Áreas Demandantes de Información y Uso Actual	17
1.6 Objetivos por Área y Necesidades Detectadas	18
1.7 KPI Relevantes	18
1.7.1 KPI de Clientes	18
1.7.2 KPI de Marketing	19
1.7.3 KPI Operativos	19
1.7.4 KPI Inventario	19
1.7.5 KPI Estratégicos	19
1.8 Enfoque de Impacto Gerencial	19
Capitulo 2	20
2.1 Origen de Datos y Arquitectura Inicial	20
2.1.1 Origen de la Información Interna	20
2.2 ERP – Sistema Contable y de Facturación	20
2.3 Sistema de Órdenes de Trabajo (OT)	21
2.3.1 Historial de Vehículos (No CRM formal)	21
2.4 Inventario	21
2.4.1 Proveedores	22
2.5 NPS y Calidad	22
2.6 Origen de Información Externa	22
2.6.1 Plataformas Digitales	22
2.6.2 Recurrencia de Carga	23
2.7 Sistemas y Destino de la Carga	23
2.7.1 Sistemas de Origen	23
2.7.2 Procesos ETL	24

2.8	Arquitectura de Data Warehouse y Datamarts	24
2.8.1	Data Warehouse.....	24
2.8.2	Datamarts.....	25
2.9	Carencias Replanteadas (Ajuste Conceptual)	25
2.10	Informes Actuales y Brechas Analíticas.....	26
Capítulo 3		26
3.1	Procesos ETL y Gobierno del Dato.....	26
3.1.1	Procesos de Carga de Datos (ETL)	26
3.2	Estrategia de Integración de Datos	27
3.2.1	Carga automática vía API (Modelo principal)	27
3.3	Modelo de Gobierno del Dato	27
3.3.1	Roles Definidos	27
3.4	Proceso de Transformación (T) en el Modelo ETL	28
3.5	Indicadores Estratégicos y Precisión Metodológica	28
3.5.1	NPS – Fuente y Tratamiento.....	28
3.5.2	ROMI – Ajuste Metodológico	28
3.6	Justificación de SQL Server como Plataforma Central	29
3.7	Arquitectura Progresiva por Fases	29
3.8	Herramientas Seleccionadas (Versión Simplificada y Realista)	30
3.9	Construcción de Dashboards Gerenciales	30
3.10	Enfoque Metodológico para la Toma de Decisiones	31
Capítulo 4		31
4.1	Visualización Estratégica	31
4.1.1	Power BI como herramienta central.....	31
4.1.2	Principios de Visualización.....	32
4.2	Dashboards por Perfil de Usuario	32
4.2.1	Dashboard Gerencial Estratégico	32
4.2.2	Dashboard Comercial y Marketing	33
4.2.3	Dashboard Financiero	33
4.2.4	Dashboard Servicio Técnico y Atención.....	34
4.3	Seguridad y Gobernanza en la Visualización	34
4.4	Indicadores Finales Seleccionados	35
4.5	Flujo de Información.....	35
4.6	Diferenciación entre Visualización y Analítica Avanzada	35

Capítulo 5.....	36
5.1 Business Case y Creación del Departamento BI	36
5.1.1 Situación Estratégica Actual	36
5.2 Origen del NPS	36
5.3 Inversión del Proyecto (Unificada)	37
5.4 Supuestos Base del Modelo (Unificados).....	37
5.5 Modelo Financiero Consolidado	38
5.6 Sensibilidad del Modelo.....	39
5.7 Impacto Estratégico Complementario	39
5.8 Creación del Departamento BI.....	39
5.8.1 Analista de Business Intelligence y Big Data	39
PARTE II:.....	41
Capítulo 1.....	41
1.1 Integración de Datos No Estructurados	41
1.2 Extensión del DWH hacia Datos No Estructurados	41
1.3 Fuentes Internas No Estructuradas Prioritarias.....	41
1.3.1 Agenda de Citas.....	41
1.3.2 WhatsApp Business	42
1.3.3 Reseñas y Redes Sociales	42
1.4 Fuentes Externas Relevantes	43
1.5 Priorización de Casos de Uso.....	43
1.6 Justificación del Big Data en el Proyecto.....	44
1.6.1 Variedad	44
1.6.2 Velocidad.....	44
1.6.3 Valor.....	44
1.7 Big Data como Habilitador del Next Best Action	44
1.8 Impacto Transversal por Área	45
1.9 Resultado Esperado.....	45
Capítulo 2.....	46
2.1 Arquitectura Cloud y Selección Tecnológica	46
2.2 Evaluación de Proveedores Cloud.....	46
2.3 Justificación Estratégica de Google Cloud Platform	46
2.3.1 Integración Analítica	47
2.3.2 Integración con Marketing Digital (Ventaja Competitiva).....	47

2.4	Arquitectura Propuesta.....	47
2.5	Identificadores Comunes y Puntos de Integración	48
2.5.1	ID_Cliente	48
2.5.2	Teléfono (Identificador Puente).....	48
2.5.3	Placa del Vehículo	48
2.5.4	Número de Orden de Trabajo (OT).....	49
2.6	Proceso Técnico de Integración	49
2.7	Flujo de Arquitectura	49
2.8	Conexión con Casos de Uso Prioritarios	50
2.9	Beneficios Estratégicos	50
Capítulo 3		53
3.1	Stack Tecnológico y Casos de Uso	53
3.2	Stack Tecnológico Final Definido.....	53
3.3	Justificación de la Simplificación.....	54
3.4	Casos de Uso Prioritarios	54
3.4.1	Caso de Uso 1: Alerta de Abandono	54
3.4.2	Caso de Uso 2: Optimización de ROMI.....	55
3.4.3	Caso de Uso 3: Cruce NPS – Recompra	55
3.4.4	Caso de Uso 4: Gestión Inteligente de Agenda	55
3.5	Integración entre Capas	56
3.6	Rol Estratégico del Ecosistema	56
3.7	Impacto Estratégico.....	56
Capítulo 4		57
4.1	Inteligencia Artificial Aplicada	57
4.2	Relación con Indicadores Estratégicos	57
4.3	Objetivo Estratégico de la IA	58
4.4	Impacto Operativo Proyectado.....	58
4.5	Impacto en Ingresos	59
4.6	Impacto en Margen (30% Oficial del Proyecto)	59
4.7	ROI Incremental de la IA	59
4.7.1	Aclaración metodológica clave	60
4.8	Nota de Coherencia Metodológica	60
4.8.1	Relación entre Modelo Mensual y Modelo Anual.....	60
4.9	Escenario Prudente (Sensibilidad).....	61

Capítulo 5.....	62
5.1 Big Data y Activación en Tiempo Real.....	62
5.2 Problemática Inicial	62
5.3 Fuentes de Datos (Consistentes con Semanas Previas)	63
5.3.1 Internas	63
5.3.2 Digitales.....	64
5.3.3 Externas	64
5.4 Área de Aplicación Principal	64
5.5 Identificación de la Mejora Esperada	65
5.6 Business Case Final (Unificado y Coherente)	65
5.6.1 Supuestos Base Oficiales	65
5.7 Explicación Ejecutiva	67
5.8 Impacto Estratégico Transversal	67
Capítulo 6 CONCLUSIONES Y APLICACIONES.....	67
Capítulo 7 REFERENCIAS BIBLIOGRÁFICAS.....	69

INDICE DE FIGURAS Y TABLAS

Tabla 1 Inversión anual del proyecto BI	37
Tabla 2 . Supuestos base del modelo financiero	39
Tabla 3 Escenario conservador – Impacto financiero	45
Tabla 4 Escenario realista – Impacto financiero	57
Tabla 5 Sensibilidad del modelo	58
Tabla 6 . Impacto proyectado de la Inteligencia Artificial.....	60
Tabla 7 ROI incremental de la fase IA	61
Tabla 8 . Escenario prudente – Sensibilidad IA.....	63
Tabla 9 Escenario conservador – Impacto financiero proyectado (10% incremento en ventas)	64
Tabla 10 Fuentes y impactos	64
Tabla 11 ROI incremental de la fase de Inteligencia Artificial.....	66
Ilustración 1 Flujo end-to end	52

INTRODUCCIÓN Y OBJETO DEL PROYECTO

Contexto Organizacional

Oña Rodríguez Ingeniería Automotriz es una PYME del sector automotriz con 15 años de trayectoria, certificada bajo estándares Bosch Car Service. La empresa cuenta con sistemas operativos estructurados (ERP, órdenes de trabajo, inventario y plataformas digitales), pero presenta una madurez analítica limitada.

Problema Estratégico

La organización dispone de datos, pero carece de integración analítica que permita:

- Comprender el ciclo de vida del cliente.
- Medir el impacto económico del marketing.
- Anticipar abandono.
- Optimizar frecuencia y recompra.
- Maximizar el Customer Lifetime Value (CLV).

Objetivo General

Diseñar un modelo integral de Business Intelligence, Big Data e Inteligencia Artificial que permita transformar datos operativos en decisiones estratégicas orientadas a incrementar retención, recurrencia y rentabilidad sostenible.

Alcance

El proyecto abarca:

- Integración de fuentes estructuradas y no estructuradas.
- Diseño de Data Warehouse.
- Visualización ejecutiva.
- Business Case financiero.
- Implementación progresiva de IA.

- Activación en tiempo real.

PARTE I: BUSINESS INTELLIGENCE Y FUNDAMENTOS ANALÍTICOS

Capítulo 1

1.1 Diagnóstico Estratégico y Definición del Problema

Oña Rodríguez Ingeniería Automotriz es una PYME del sector automotriz ecuatoriano con 15 años de trayectoria, especializada en mantenimiento y reparación de vehículos, venta de repuestos y servicio técnico certificado bajo la red internacional Bosch Car Service.

La empresa opera bajo procesos estandarizados 100% Fit, con enfoque en calidad técnica, cumplimiento de tiempos y experiencia del cliente. En su fase actual de expansión y profesionalización, la organización busca evolucionar desde una gestión operativa basada en reportes descriptivos hacia una gestión estratégica soportada en analítica avanzada y toma de decisiones basada en datos.

1.2 Definición del Problema y Objetivos Iniciales del Proyecto

1.2.1 Definición Estratégica del Problema

Actualmente, la empresa genera información proveniente de:

- Órdenes de trabajo (OT)
- Ventas de repuestos y mano de obra
- Registros de clientes y vehículos
- Campañas de marketing (redes sociales, radio, referidos, orgánico)
- Encuestas de satisfacción

Si bien estos datos se registran en tiempo real mediante sistemas como Contífico, su uso es predominantemente descriptivo y fragmentado. No existe una integración analítica que permita comprender el ciclo de vida del cliente, medir el retorno real de marketing ni anticipar comportamientos de recompra, abandono o rentabilidad por segmento.

El problema central no radica únicamente en la falta de integración tecnológica, sino en la ausencia de un modelo analítico que conecte clientes, campañas, servicios y resultados financieros dentro de una misma arquitectura de decisión.

Esto limita la capacidad de la gerencia para:

- Priorizar clientes de alto valor.
- Asignar presupuesto a los canales más rentables.
- Anticipar patrones de recompra o abandono.
- Vincular eficiencia operativa con retención y margen.

Es importante enfatizar que la implementación de Business Intelligence no incrementa la rentabilidad por sí sola; sin embargo, habilita decisiones estratégicas basadas en evidencia que reducen la incertidumbre y optimizan la asignación de recursos.

Una mejora estimada del 5–10% en la retención de clientes de alto valor puede generar un incremento significativo en el Customer Lifetime Value (CLV) agregado del negocio, impactando directamente el margen de contribución y la sostenibilidad financiera del taller.

La cadena de valor esperada es:

Integración de datos → Segmentación inteligente → Optimización de inversión en marketing → Mayor recompra y menor churn → Incremento del CLV → Mayor margen y rentabilidad sostenible.

1.3 Enfoque BI & Big Data

El proyecto propone diseñar una arquitectura de datos escalable basada en:

- Data Warehouse estructurado
- Posible Data Lake para expansión futura
- Modelo analítico centrado en el cliente

Se aplicarán técnicas de:

- Análisis de cohortes

- Segmentación avanzada
- Cálculo aproximado de CLV
- Medición de ROMI y CAC

El sistema no se limitará a describir el pasado, sino que evolucionará progresivamente hacia modelos predictivos de propensión a recompra y abandono.

Además, se incorporará un marco de gobierno de datos que contemple:

- Calidad
- Seguridad
- Privacidad
- Roles de responsabilidad

Garantizando que la información utilizada para la toma de decisiones sea confiable y trazable.

1.4 Objetivos Iniciales del Proyecto

1. Consolidar los datos de ventas, órdenes de trabajo, clientes y campañas en una plataforma centralizada de BI.
2. Calcular indicadores de recompra, frecuencia de visita y retención mediante análisis de cohortes.
3. Identificar clientes de alto, medio y valor estándar, estimando su CLV.
4. Medir el ROMI por canal y vincularlo con el margen de contribución.
5. Implementar tableros ejecutivos integrados para la Gerencia General.
6. Establecer lineamientos formales de gobierno de datos.

1.5 Áreas Demandantes de Información y Uso Actual

La información actualmente se utiliza de forma operativa y aislada:

Servicio Técnico: control de tiempos y ejecución de OT.

Repuestos: rotación e inventario.

Marketing: registro de campañas sin medición integral de impacto.

Finanzas: estados financieros tradicionales.

Gerencia General: reportes parciales sin visión 360° del cliente.

El proyecto busca transformar esta estructura fragmentada en una visión integrada que conecte:

Cliente + Servicio + Canal + Rentabilidad.

1.6 Objetivos por Área y Necesidades Detectadas

Servicio Técnico

- Relacionar productividad con retención.
- Medir impacto de retrabajos en satisfacción.

Repuestos

- Identificar productos que incrementan ticket promedio en clientes de alto valor.
- Analizar margen por categoría y segmento.

Marketing

- Identificar canales que generan clientes con mayor CLV.
- Optimizar inversión según contribución marginal.

Finanzas

- Medir margen de contribución por segmento y canal.
- Evaluar impacto financiero de decisiones comerciales.

Gerencia General

- Acceder a tableros ejecutivos integrados.
- Visualizar crecimiento, rentabilidad y proyecciones.

1.7 KPI Relevantes

1.7.1 KPI de Clientes

- Tasa de retención

- Tasa de recompra
- Frecuencia de visita
- CLV estimado
- NPS

1.7.2 KPI de Marketing

- ROMI
- CAC
- Tasa de conversión por canal
- Ticket promedio por segmento

1.7.3 KPI Operativos

- Productividad técnica
- Tasa de retrabajo
- Cumplimiento de tiempos prometidos

1.7.4 KPI Inventario

- Rotación
- Margen por categoría
- Stock muerto

1.7.5 KPI Estratégicos

- Margen de contribución por segmento
- Crecimiento de ventas

1.8 Enfoque de Impacto Gerencial

El sistema permitirá:

- Priorizar inversión en clientes de alto valor.
- Reducir churn mediante acciones segmentadas.

- Reasignar presupuesto hacia canales con mayor retorno.
- Optimizar mezcla de servicios y repuestos.
- Fortalecer la planificación financiera basada en comportamiento real de clientes.

El BI deja de ser una herramienta de reporte y se convierte en un sistema de soporte a decisiones estratégicas.

Capítulo 2

2.1 Origen de Datos y Arquitectura Inicial

2.1.1 Origen de la Información Interna

A diferencia de lo planteado inicialmente, la empresa sí dispone de sistemas operativos estructurados. El desafío no es la ausencia de datos, sino su falta de integración analítica.

2.2 ERP – Sistema Contable y de Facturación

La empresa utiliza **Contífico** como sistema ERP para:

- Facturación electrónica.
- Registro contable.
- Control de inventario.
- Registro de clientes.
- Estados financieros históricos.

En este sistema se almacenan:

- Base de datos de clientes con su historial transaccional.
- Información de ventas de servicios y repuestos.
- Movimientos de inventario.
- Información contable y financiera.

Contífico constituye la principal fuente estructurada de datos económicos y transaccionales.

2.3 Sistema de Órdenes de Trabajo (OT)

La gestión operativa del taller se realiza mediante un sistema interno de órdenes de trabajo, donde se registra:

- Tipo de servicio.
- Técnico asignado.
- Tiempos estimados y reales.
- Estado de la OT.
- Relación OT–cliente–vehículo.

Este sistema está vinculado a la facturación del ERP, permitiendo identificar cada orden por cliente y vehículo.

2.3.1 Historial de Vehículos (No CRM formal)

La empresa no dispone actualmente de un CRM independiente.

El historial detallado de cada vehículo (trabajos realizados, repuestos instalados, kilometraje como bitácora) se registra dentro del sistema de órdenes de trabajo y se vincula al cliente a través del ERP.

Por tanto, el proyecto de BI no parte de ausencia de CRM, sino de la necesidad de consolidar esta información en una visión 360° del cliente.

2.4 Inventario

El inventario se gestiona dentro del módulo correspondiente en Contífico (ERP), donde se registran:

- Cantidades.
- Costos.
- Precios de venta.
- Margen por producto.

No existe dispersión tecnológica; sin embargo, no se realiza análisis predictivo de rotación ni vinculación estratégica con campañas y proveedores.

2.4.1 Proveedores

La información de proveedores se gestiona parcialmente en el ERP (facturación y compras) y parcialmente en registros internos (planillas estructuradas), donde se documentan:

- Tipo de proveedor (importador, distribuidor, mayorista).
- Condiciones de crédito.
- Garantías.
- Acuerdos comerciales.
- Disponibilidad de productos demo.

La oportunidad de mejora no es la falta de datos, sino su sistematización analítica y estructuración para ranking estratégico.

2.5 NPS y Calidad

Los datos de NPS se recogen mediante formularios posteriores al servicio.

Actualmente:

- Se registran a nivel individual.
- No se integran al ERP de manera estructurada.
- No se vinculan sistemáticamente con comportamiento de recompra ni CLV.

El problema no es la ausencia de medición, sino la falta de explotación analítica.

2.6 Origen de Información Externa

2.6.1 Plataformas Digitales

Los datos de marketing se obtienen desde:

- Meta Business Suite (Facebook e Instagram).
- Google Ads.
- Google Analytics.
- Google My Business.

Estas plataformas ya proveen dashboards digitales con métricas como:

- Alcance.
- Interacciones.
- Leads.
- Inversión.
- Clics.

La oportunidad de BI consiste en integrar estas métricas con:

- Clientes reales captados.
- Ticket promedio.
- Frecuencia de visita.
- CLV por canal.

2.6.2 Recurrencia de Carga

La frecuencia de carga propuesta es:

- Diaria: ventas, OT, inventario.
- Semanal: métricas de campañas.
- Mensual: estados financieros, segmentación, CLV, ROMI.

Dado el tamaño y naturaleza de la empresa (PYME automotriz), esta recurrencia es suficiente para la toma de decisiones estratégicas.

No se requiere procesamiento en tiempo real, sino análisis estructurado y periódico que permita ajustes tácticos y estratégicos.

2.7 Sistemas y Destino de la Carga

2.7.1 Sistemas de Origen

Los datos provienen de:

- ERP Contífico (facturación, contabilidad, inventario).

- Sistema de Órdenes de Trabajo.
- Formularios de NPS.
- Meta Business Suite.
- Google Ads y Google Analytics.
- Registros internos estructurados de proveedores.

2.7.2 Procesos ETL

El proceso ETL contempla:

1. Extracción desde los sistemas mencionados.
2. Transformación:
 - Limpieza de datos.
 - Normalización de nombres.
 - Unificación de identificadores.
3. Carga:
 - Área staging.
 - Data Warehouse corporativo.

El Data Warehouse se convierte en la “single source of truth” analítica.

2.8 Arquitectura de Data Warehouse y Datamarts

2.8.1 Data Warehouse

Tablas de hechos:

- Hecho_Ventas.
- Hecho_OT_Servicio.
- Hecho_Marketing.
- Hecho_Proveedor.
- Hecho_Interacción_Cliente.

Dimensiones:

- Dim_Cliente.
- Dim_Vehículo.
- Dim_Producto.
- Dim_Proveedor.
- Dim_Técnico.
- Dim_Canal.
- Dim_Tiempo.

2.8.2 Datamarts

- Datamart Clientes & Marketing.
- Datamart Servicio Técnico.
- Datamart Inventario.
- Datamart Proveedores.
- Datamart Financiero & ROI.

2.9 Carencias Replanteadas (Ajuste Conceptual)

Se corrige el planteamiento inicial.

La empresa no presenta un problema crítico de dispersión tecnológica.

Las carencias identificadas son:

- Falta de integración analítica entre sistemas.
- Ausencia de identificador único transversal cliente–vehículo–canal.
- No explotación avanzada de NPS.
- No análisis predictivo de stock.
- No ranking estratégico de proveedores.
- Procesos semimanuales en consolidación.

El desafío es de madurez analítica, no de inexistencia de datos.

2.10 Informes Actuales y Brechas Analíticas

Actualmente existen:

- Reportes operativos.
- Estados financieros.
- Reportes de inventario.
- Métricas digitales.

Sin embargo, no existe:

- Visión 360° del cliente.
- Medición integrada de ROMI y CLV.
- Dashboard ejecutivo consolidado.
- Modelo analítico para decisiones estratégicas.

El proyecto de BI permitirá transformar datos operativos existentes en inteligencia estratégica.

Capítulo 3

3.1 Procesos ETL y Gobierno del Dato

3.1.1 Procesos de Carga de Datos (ETL)

La empresa genera información principalmente desde:

- ERP Contífico (facturación, inventario, clientes, contabilidad).
- Sistema interno de Órdenes de Trabajo.
- Formularios digitales de NPS (Google Forms).
- Meta Business Suite y Google Ads.
- Google Sheets estructurados.

Dado que la organización aún no dispone de un Data Warehouse consolidado, se define como estrategia principal la implementación de una arquitectura automatizada basada en SQL Server como repositorio central.

3.2 Estrategia de Integración de Datos

Se establece como enfoque prioritario:

3.2.1 Carga automática vía API (Modelo principal)

Contífico ofrece servicios de integración mediante API, lo que permite:

- Extraer información de forma programada.
- Automatizar consultas periódicas.
- Evitar procesos manuales.
- Reducir riesgo de error humano.
- Garantizar trazabilidad.

Los datos provenientes de Google Sheets y formularios NPS se integrarán también mediante APIs oficiales de Google.

La carga manual solo se contempla como mecanismo transitorio en fase inicial o contingencia, pero no como base estructural de la estrategia de datos.

Este enfoque asegura sostenibilidad, escalabilidad y coherencia con una visión de madurez analítica.

3.3 Modelo de Gobierno del Dato

Se redefine la estructura de responsabilidad para mayor claridad.

3.3.1 Roles Definidos

- Data Owner
Gerente General.
Responsable estratégico del uso del dato y alineación con objetivos de negocio.
- Data Steward
Responsables por área (Finanzas, Servicio Técnico, Marketing).
Encargados de la calidad operativa del dato en su proceso.

- Data Custodian
Responsable técnico (arquitectura SQL y procesos ETL).
Encargado de seguridad, integridad y respaldo.

Esta diferenciación evita concentrar toda la responsabilidad en la alta gerencia y distribuye adecuadamente funciones de control, calidad y validación.

3.4 Proceso de Transformación (T) en el Modelo ETL

La transformación constituye el núcleo estratégico del proyecto.

Se divide en dos capacidades progresivas:

- Reportería y Análisis Descriptivo
- Analítica y Segmentación Avanzada

No se plantea minería compleja en fase inicial, sino evolución progresiva.

3.5 Indicadores Estratégicos y Precisión Metodológica

3.5.1 NPS – Fuente y Tratamiento

El NPS se obtiene mediante:

- Formularios digitales enviados post-servicio (Google Forms).
- Registro individual por cliente.

No es gestionado por un tercero externo.

Actualmente se encuentra almacenado en Google Sheets y será integrado al SQL Server mediante API, permitiendo vincular satisfacción con:

- Frecuencia.
- Recompra.
- Segmento.
- CLV.

3.5.2 ROMI – Ajuste Metodológico

Se reconoce que el cálculo de ROMI presenta desafíos de atribución.

Por ello, el modelo se plantea bajo un esquema progresivo:

Fase 1:

- Identificación del canal declarado por el cliente.
- Modelo de atribución simple (último canal registrado).

Fase 2:

- Análisis comparativo por cohortes.
- Evaluación de comportamiento post-campaña.

No se plantea un modelo perfecto de atribución, sino una aproximación razonable y mejorable.

Esto evita sobreestimaciones y mantiene rigor analítico.

3.6 Justificación de SQL Server como Plataforma Central

SQL Server se define como repositorio central por:

- Compatibilidad con herramientas BI (Power BI).
- Robustez en manejo relacional.
- Escalabilidad para crecimiento futuro.
- Modelo estructurado adecuado para hechos y dimensiones.
- Curva de aprendizaje razonable para equipo técnico.

No se selecciona por moda tecnológica, sino por equilibrio entre:

Costo – Escalabilidad – Gobernanza – Integración.

3.7 Arquitectura Progresiva por Fases

Se define un roadmap de madurez:

Fase 1 – Consolidación y Reportería

- Integración vía API.
- SQL Server como repositorio.

- Power BI como herramienta principal.
- Cálculo de KPIs estratégicos.

Fase 2 – Segmentación y Análisis de Tendencias

- Segmentación por comportamiento.
- Análisis de cohortes.
- Evaluación comparativa por períodos.

Fase 3 – Analítica Predictiva (Opcional Futuro)

- Modelos simples de propensión.
- Predicción de recompra.
- Alertas automatizadas.

No se incluyen herramientas avanzadas como RapidMiner o KNIME en fase inicial, ya que no corresponden a la madurez actual del negocio.

3.8 Herramientas Seleccionadas (Versión Simplificada y Realista)

Se define un stack coherente con una PYME automotriz:

- SQL Server – Repositorio central
- Power BI – Visualización y dashboards
- APIs Contífico y Google – Integración automática
- Python (opcional futuro) para análisis avanzado

Se eliminan herramientas sobredimensionadas para evitar incoherencia estratégica.

3.9 Construcción de Dashboards Gerenciales

Los dashboards deberán:

- Mostrar retención, frecuencia, recompra.
- Integrar NPS y segmentación.
- Visualizar evolución de ventas.
- Comparar desempeño por canal.

- Mostrar indicadores financieros vinculados.

Se prioriza:

Claridad > Complejidad

Acción > Estética

Decisión > Sobrecarga técnica

3.10 Enfoque Metodológico para la Toma de Decisiones

Cada indicador deberá responder:

- ¿Qué cliente está en riesgo?
- ¿Qué canal es más rentable?
- ¿Qué segmento genera mayor margen?
- ¿Qué proveedor impacta más en rotación?
- ¿Dónde se asigna mejor el presupuesto?

El objetivo no es medir por medir, sino orientar decisiones concretas.

Capítulo 4

4.1 Visualización Estratégica

4.1.1 Power BI como herramienta central.

La elección de Power BI se fundamenta en:

- Integración nativa con SQL Server.
- Capacidad de conexión directa y actualización automática.
- Interfaz intuitiva orientada a usuarios no técnicos.
- Creación de dashboards interactivos.
- Seguridad por roles y perfiles de acceso.
- Escalabilidad acorde al crecimiento del negocio.

La herramienta seleccionada responde al entorno ya definido, evitando sobredimensionar la arquitectura con múltiples soluciones innecesarias.

4.1.2 Principios de Visualización

La visualización se diseña bajo los siguientes principios:

1. Claridad antes que complejidad.
2. Orientación a decisiones, no a métricas aisladas.
3. Segmentación por perfil de usuario.
4. Interactividad controlada.
5. Seguridad por rol.
6. Actualización automática desde SQL Server.

El objetivo no es mostrar todos los datos, sino mostrar la información correcta para cada nivel de decisión.

4.2 Dashboards por Perfil de Usuario

4.2.1 Dashboard Gerencial Estratégico

Usuario: Gerente General

Objetivo: Toma de decisiones estratégicas.

Indicadores:

- Tasa de retención.
- Frecuencia de visita.
- Tasa de recompra.
- CLV por segmento.
- NPS global.
- ROMI por canal.
- Tendencias comparativas interanuales.

Características:

- Visión 360° del cliente.
- Comparación por períodos.
- Visualización ejecutiva consolidada.
- Sin detalle operativo individual.

4.2.2 Dashboard Comercial y Marketing

Usuarios: Gerente Comercial y Marketing

Objetivo: Optimizar campañas y captación.

Indicadores:

- Origen del cliente.
- Tasa de recompra por canal.
- Retención por segmento.
- NPS por origen.
- ROMI estimado.
- CAC.

Características:

- Análisis por campaña.
- Segmentación por tipo de cliente.
- Filtros dinámicos por período.

Restricción: No visualiza márgenes internos ni costos detallados.

4.2.3 Dashboard Financiero

Usuarios: Gerencia Financiera y Administración

Objetivo: Evaluar impacto económico.

Indicadores:

- Ingresos por segmento.

- Recurrencia de clientes.
- Valor promedio por cliente.
- Impacto económico de retención.
- Margen de contribución asociado a comportamiento.

Restricción: No visualiza NPS ni detalle operativo técnico.

4.2.4 Dashboard Servicio Técnico y Atención

Usuarios: Jefatura de Taller y Atención al Cliente

Objetivo: Mejorar experiencia y fidelización.

Indicadores:

- NPS por servicio.
- Frecuencia por cliente.
- Recompra asociada a tipo de servicio.
- Historial de visitas.

Restricción: No accede a información financiera.

4.3 Seguridad y Gobernanza en la Visualización

La visualización se rige por:

- Acceso por rol.
- Control de permisos en Power BI.
- Segmentación de datos por perfil.
- Protección de información sensible.
- Registro de accesos y auditoría.

La arquitectura asegura que cada usuario visualice únicamente la información pertinente a su responsabilidad.

4.4 Indicadores Finales Seleccionados

Tras evaluar la calidad y confiabilidad de los datos, se definió concentrar la visualización en los siguientes KPIs:

1. Tasa de retención.
2. Frecuencia de visita.
3. Tasa de recompra.
4. Valor del cliente por segmento (CLV estimado).
5. NPS.
6. ROMI estimado.

Se excluyeron indicadores que no cuentan con trazabilidad histórica consistente (como inventarios detallados, productividad técnica exhaustiva o cartera vencida estructurada), priorizando precisión y confiabilidad.

4.5 Flujo de Información

El flujo operativo de visualización es:

Contífico + Google Sheets

- API automática
- SQL Server (Data Warehouse)
- Power BI
- Dashboards por rol

Esto garantiza:

- Actualización periódica.
- Eliminación de cargas manuales.
- Integridad del dato.
- Consistencia entre áreas.

4.6 Diferenciación entre Visualización y Analítica Avanzada

La visualización corresponde a la capa de presentación de información.

La analítica avanzada (segmentación con algoritmos como K-means o modelos predictivos) se considera una fase futura dentro de la madurez analítica del negocio.

En esta etapa, el foco está en:

Visualizar correctamente → Analizar tendencias → Tomar decisiones.

No en implementar minería compleja innecesaria para el contexto actual.

Capítulo 5

5.1 Business Case y Creación del Departamento BI

5.1.1 Situación Estratégica Actual

La empresa cuenta con información contable y operativa estructurada; sin embargo, no dispone de un modelo analítico integrado que permita evaluar de manera sistemática:

- Retención de clientes
- Recompra
- Frecuencia de visita
- Segmentación por valor
- Relación entre NPS y comportamiento económico

La tasa actual de retención es del 52%, lo que implica que 48 de cada 100 clientes no regresan en el siguiente período. Esta situación genera dependencia constante de captación externa y pérdida de valor económico potencial del cliente.

El problema no es la ausencia de datos, sino la falta de integración estratégica de los mismos.

5.2 Origen del NPS

El NPS es levantado internamente mediante formularios digitales posteriores al servicio (Google Forms), almacenados en Google Sheets.

Actualmente:

- Se registra a nivel individual.
- No está vinculado con recompra ni CLV.
- No se utiliza como variable predictiva.

El proyecto BI permitirá integrar el NPS con frecuencia, retención y margen, convirtiéndolo en un indicador económico estratégico.

5.3 Inversión del Proyecto (Unificada)

TABLA 1 INVERSIÓN ANUAL DEL PROYECTO BI

Concepto	Valor Anual (USD)
Contífico Premium (API)	539,69
Power BI Licencias	317,80
SQL Server Standard	1.449,00
Capacitaciones	600,00
Analista BI Junior	8.400,00
Total Inversión Anual	11.306,49

Nota. Elaboración propia con base en datos internos del proyecto

✓ Este valor se mantiene uniforme en todo el proyecto.

5.4 Supuestos Base del Modelo (Unificados)

Para garantizar coherencia financiera con el proyecto global, se establecen los siguientes supuestos:

- Clientes activos anuales: **1.000**
- Ingreso promedio anual por cliente: **USD 1.000**
- Facturación anual estimada: **USD 1.000.000**
- Margen operativo oficial del proyecto: **30%**
- Retención actual: 52%

Se elimina el margen del 35% y el ticket de USD 1.029 para garantizar consistencia con las fases posteriores.

5.5 Modelo Financiero Consolidado

En lugar de proyectar únicamente mejora por puntos porcentuales aislados de retención, se consolida el análisis bajo escenarios de impacto integral en ventas y margen, coherente con las fases posteriores del proyecto.

- **Escenario Conservador (Impacto Integral 10%)**

Incremento ventas:

$$\text{USD } 1.000.000 \times 10\% = \text{USD } 100.000$$

Utilidad incremental (30% margen):

$$\text{USD } 100.000 \times 30\% = \text{USD } 30.000$$

$$\text{ROI} = (30.000 - 11.306,49) / 11.306,49$$

$$\text{ROI} \approx 173\%$$

Payback estimado: 4–5 meses

- **Escenario Realista (Impacto Integral 20%)**

Incremento ventas:

$$\text{USD } 1.000.000 \times 20\% = \text{USD } 200.000$$

Utilidad incremental (30% margen):

$$\text{USD } 200.000 \times 30\% = \text{USD } 60.000$$

$$\text{ROI} \approx 445\%$$

Payback estimado: 2–3 meses

5.6 Sensibilidad del Modelo

TABLA 2 . SUPUESTOS BASE DEL MODELO FINANCIERO

Escenario	Incremento Ventas	Utilidad Incremental	ROI
10%	100.000	30.000	173%
20%	200.000	60.000	445%

Nota. Elaboración propia con base en datos internos del proyecto

El proyecto demuestra solidez incluso en escenarios conservadores, sin depender de crecimiento extremo.

5.7 Impacto Estratégico Complementario

Más allá del ROI financiero directo, el proyecto habilita:

- Optimización de ROMI mediante reasignación eficiente de marketing.
- Incremento en frecuencia y ticket promedio.
- Mejora estructural del CLV.
- Reducción de churn.
- Mayor previsibilidad financiera.
- Planeación estratégica basada en datos.

Estos beneficios refuerzan la sostenibilidad del modelo más allá del cálculo numérico.

5.8 Creación del Departamento BI

Se establece el rol transversal de:

5.8.1 Analista de Business Intelligence y Big Data

Dependencia: Gerencia General

Funciones:

- Integrar datos estructurados y no estructurados.
- Modelar indicadores estratégicos.
- Construir dashboards ejecutivos.
- Evaluar impacto financiero.
- Impulsar cultura organizacional data-driven.

El departamento no constituye un gasto adicional, sino un habilitador estratégico de rentabilidad y estabilidad.

PARTE II: BIG DATA, CLOUD E INTELIGENCIA ARTIFICIAL

Capítulo 1

1.1 Integración de Datos No Estructurados

En las etapas anteriores del proyecto se diseñó e implementó un **Data Warehouse relacional tipo estrella centrado en el cliente**, soportado en SQL Server, que integra información estructurada de:

- Clientes
- Visitas y servicios
- Facturación
- Campañas
- NPS

En esta fase, el objetivo no es rediseñar el modelo existente, sino **extenderlo** para incorporar fuentes de datos no estructurados y externas que permitan enriquecer el análisis y evolucionar hacia un enfoque de Next Best Action.

1.2 Extensión del DWH hacia Datos No Estructurados

El modelo estrella ya implementado en el DWH servirá como núcleo estructural.

La incorporación de datos no estructurados se realizará mediante:

- Procesos ETL adicionales.
- Normalización de metadatos.
- Tablas puente para vincular texto libre con identificadores de cliente.

El DWH no se reemplaza; se amplía.

1.3 Fuentes Internas No Estructuradas Prioritarias

1.3.1 Agenda de Citas

Fuente: Google Calendar / sistema de turnos.

Valor analítico:

- Identificación de no-show.
- Lead time entre contacto y servicio.
- Estacionalidad por tipo de servicio.
- Anticipación de frecuencia real.

Acción clave:

Estandarizar estados (realizada, reprogramada, no-show) y vincular con facturación.

1.3.2 WhatsApp Business

Canal crítico para la PYME.

Datos potenciales:

- Motivo de consulta.
- Categoría de servicio.
- Tiempo de primera respuesta.
- Evidencia fotográfica.
- Seguimiento post-servicio.

Riesgo actual:

Información queda en el chat sin estructurarse.

Solución:

Implementar checklist de cierre que registre resultado en sistema estructurado.

1.3.3 Reseñas y Redes Sociales

Fuente:

- Google Reviews.
- Facebook.
- Instagram.

Valor estratégico:

- Identificación de objeciones (precio, tiempo, calidad).
- Clasificación de comentarios.
- Detección de patrones por período.
- Relación reputación–retención.

El texto libre puede clasificarse en categorías para análisis cuantificable.

1.4 Fuentes Externas Relevantes

No se integran como datos operativos, sino como contexto estratégico:

- AEADE (ventas sectoriales).
- INEC (estructura empresarial).
- Fideval (dinámica de mercado).
- Mentinno (presencia digital).

Uso estratégico:

- Anticipar composición futura del parque automotor.
- Ajustar mix de servicios.
- Planificar capacitación técnica.
- Optimizar campañas por segmento emergente.

1.5 Priorización de Casos de Uso

Dado que la empresa es una PYME, no se implementarán todos los casos simultáneamente.

Fase 1 – Alta Prioridad (Viabiles y de mayor impacto)

1. Automatización de alertas de abandono.
2. Cruce NPS – frecuencia – recompra.
3. Medición básica de ROMI por campaña.

Fase 2 – Prioridad Media

4. Clasificación automática de reseñas.

5. Score de riesgo de abandono.

Fase 3 – Evolución Estratégica

6. Integración sectorial para planificación anticipada.

7. Modelo completo de Next Best Action.

Esta priorización garantiza viabilidad operativa.

1.6 Justificación del Big Data en el Proyecto

El proyecto no maneja grandes volúmenes masivos de datos.

Por lo tanto, el Big Data no se justifica por volumen.

Se justifica por:

1.6.1 Variedad

Integración de:

- Datos estructurados.
- Texto libre.
- Metadatos.
- Información sectorial externa.

1.6.2 Velocidad

Reducción del tiempo entre:

Evento → Análisis → Decisión → Acción.

1.6.3 Valor

Capacidad de generar acciones personalizadas basadas en comportamiento real.

El Big Data en este contexto representa la integración inteligente de múltiples fuentes heterogéneas para habilitar decisiones oportunas.

1.7 Big Data como Habilitador del Next Best Action

El flujo conceptual es:

1. Evento (ausencia prolongada, NPS bajo, consulta específica).
2. Integración de datos estructurados y no estructurados.
3. Evaluación de riesgo o propensión.
4. Definición de acción óptima.
5. Ejecución y medición de impacto.

No se trata de complejidad tecnológica, sino de capacidad analítica aplicada.

1.8 Impacto Transversal por Área

TABLA 3 ESCENARIO CONSERVADOR – IMPACTO FINANCIERO

Área	Impacto
Comercial	Segmentación más precisa
Atención	Gestión proactiva de reclamos
Operativa	Optimización de agenda
Inventarios	Demanda anticipada
Gerencia	Decisiones basadas en evidencia

Nota. Elaboración propia con base en datos internos del proyecto

1.9 Resultado Esperado

Con la integración de datos no estructurados, la empresa podrá:

- Detectar abandono temprano.
- Mejorar experiencia del cliente.
- Optimizar campañas.
- Anticipar demanda.
- Incrementar fidelización.

El proyecto evoluciona desde BI descriptivo hacia una gestión predictiva progresiva

Capítulo 2

2.1 Arquitectura Cloud y Selección Tecnológica

En las etapas previas del proyecto se consolidó un Data Warehouse relacional en SQL Server con modelo tipo estrella centrado en el cliente.

En esta fase se propone la extensión de la arquitectura hacia un entorno Cloud que permita:

- Escalabilidad.
- Integración de datos no estructurados.
- Automatización.
- Activación digital.
- Evolución hacia analítica avanzada.

El objetivo no es reemplazar el DWH existente, sino complementarlo estratégicamente.

2.2 Evaluación de Proveedores Cloud

Se analizaron tres principales proveedores:

- Amazon Web Services (AWS)
- Microsoft Azure
- Google Cloud Platform (GCP)

La selección se realizó considerando:

- Integración con entorno actual.
- Facilidad de implementación para PYME.
- Costos.
- Capacidad analítica.
- Conexión con marketing digital.

2.3 Justificación Estratégica de Google Cloud Platform

Google Cloud Platform se selecciona por:

2.3.1 Integración Analítica

- BigQuery como motor de análisis masivo.
- Procesamiento de datos estructurados y no estructurados.
- Conexión directa con SQL Server.
- Servicios de IA nativos.

2.3.2 Integración con Marketing Digital (Ventaja Competitiva)

Para Oña Rodríguez, esta es una ventaja clave.

GCP permite:

- Conexión directa con Google Ads.
- Integración con Google Analytics.
- Creación de audiencias basadas en datos reales.
- Activación automática de campañas.
- Medición de conversiones offline.
- Optimización de ROMI en tiempo casi real.

Esto facilita la ejecución de acciones de marketing digital basadas en comportamiento real del cliente.

No solo se analiza; se activa.

2.4 Arquitectura Propuesta

La arquitectura se compone de:

- Fuentes estructuradas (ERP, OT, inventario).
- Fuentes no estructuradas (WhatsApp, reseñas, agenda).
- Landing Zone en GCP.
- Procesamiento y normalización.
- Integración con DWH SQL existente.
- Visualización y activación.

El Data Warehouse mantiene su modelo estrella consolidado.

2.5 Identificadores Comunes y Puntos de Integración

La integración entre Big Data y DWH requiere identificadores únicos.

Se definen los siguientes:

2.5.1 ID_Cliente

Clave primaria central del modelo.

Se construye a partir de:

- Número de cédula.
- Teléfono normalizado.
- Correo electrónico.
- Código interno ERP.

2.5.2 Teléfono (Identificador Puente)

Fundamental para:

- WhatsApp Business.
- Contacto post-servicio.
- Vinculación con CRM operativo.

Proceso:

- Normalización formato internacional.
- Eliminación duplicados.
- Cruce con Dim_Cliente.

2.5.3 Placa del Vehículo

Identificador crítico en servicios automotrices.

Permite vincular:

- Historial técnico.

- Frecuencia real.
- Segmentación por tipo de vehículo.

2.5.4 Número de Orden de Trabajo (OT)

Vincula:

- Evento de servicio.
- Facturación.
- NPS.
- Interacciones post-servicio.

2.6 Proceso Técnico de Integración

Ejemplo práctico:

1. Cliente envía mensaje por WhatsApp.
2. Sistema registra número telefónico.
3. Se normaliza el formato.
4. Se cruza con Dim_Cliente.
5. Si coincide:
 - Se asigna ID_Cliente.
 - Se genera registro en Fact_Interacciones.
6. Si no coincide:
 - Se crea registro provisional.
 - Se valida manualmente.

Este proceso garantiza coherencia entre datos no estructurados y modelo relacional.

2.7 Flujo de Arquitectura

Fuentes → Landing Zone GCP → Procesamiento → Validación de identificadores → Integración DWH SQL → Power BI / Activación Marketing

La Landing Zone actúa como área de preparación y gobierno.

El DWH sigue siendo la fuente oficial consolidada.

2.8 Conexión con Casos de Uso Prioritarios

Esta arquitectura permite ejecutar:

- Alertas automáticas de abandono.
- Activación de campañas segmentadas.
- Cruce NPS – retención.
- Medición de ROMI real.
- Next Best Action.

La infraestructura Cloud habilita automatización sin sobrecargar sistemas locales.

2.9 Beneficios Estratégicos

Operativos

- Centralización de fuentes.
- Reducción de procesos manuales.
- Mejora de trazabilidad.

Comerciales

- Segmentación avanzada.
- Activación automática de marketing.
- Optimización de inversión publicitaria.

Estratégicos

- Escalabilidad futura.
- Preparación para analítica predictiva.
- Integración con ecosistema digital.

Imagen 1. Flujo end-to end

Flujo End-to-End: Arquitectura Big Data → DWH SQL Existente

Proyecto: Oña Rodríguez Ing. Aut.




ILUSTRACIÓN 1 FLUJO END-TO END

Nota. Elaboración propia con base en datos internos del proyecto

Capítulo 3

3.1 Stack Tecnológico y Casos de Uso

- Data Warehouse SQL con modelo estrella centrado en el cliente.
- Integración mediante procesos ETL automatizados.
- Extensión Big Data en entorno Google Cloud.
- Incorporación de datos no estructurados.
- Activación analítica orientada a marketing digital.

En esta etapa no se redefine la arquitectura base, sino que se formaliza el stack tecnológico final alineado con la realidad operativa de una PYME automotriz y se aterriza en casos de uso concretos.

3.2 Stack Tecnológico Final Definido

Se adopta una arquitectura simplificada y escalable compuesta por:

- **SQL Server**

Repositorio analítico central (Data Warehouse).

Modelo tipo estrella consolidado.

- **Google Cloud Platform**

Landing Zone y procesamiento Big Data.

- **Python**

Motor de automatización, limpieza, transformación y generación de alertas.

- **MongoDB (único complemento NoSQL)**

Se selecciona MongoDB para:

- Almacenamiento de datos no estructurados.
- Registro de interacciones WhatsApp.
- Diagnósticos técnicos.
- Fotografías y documentos asociados.

- Comentarios de clientes.

Se elimina Elasticsearch en esta fase para evitar sobrearquitectura innecesaria, dado que el volumen y complejidad actual no justifican su implementación.

La arquitectura mantiene simplicidad, escalabilidad y control de costos.

3.3 Justificación de la Simplificación

El objetivo no es construir una infraestructura tecnológica compleja, sino una arquitectura proporcional al tamaño y necesidades del negocio.

Para una PYME automotriz:

- SQL cubre analítica estructurada.
- MongoDB cubre datos no estructurados.
- Python permite procesamiento.
- GCP habilita escalabilidad y marketing digital.

Esta combinación es suficiente para ejecutar los casos de uso estratégicos definidos.

3.4 Casos de Uso Prioritarios

La arquitectura se orienta a resolver problemas concretos del negocio.

3.4.1 Caso de Uso 1: Alerta de Abandono

Problema:

Clientes con baja frecuencia o riesgo de no retorno.

Solución:

- Python detecta ausencia superior a umbral definido.
- Se genera alerta automática.
- Se activa campaña digital segmentada vía Google Ads.

Impacto:

Incremento de retención y CLV.

3.4.2 Caso de Uso 2: Optimización de ROMI

Problema:

Inversión en marketing sin medición precisa.

Solución:

- Integración SQL + GCP.
- Cruce entre campañas digitales y clientes reales.
- Identificación de canales con mayor margen.

Impacto:

Reasignación de presupuesto y mayor eficiencia comercial.

3.4.3 Caso de Uso 3: Cruce NPS – Recompra

Problema:

NPS medido pero no explotado.

Solución:

- MongoDB almacena feedback textual.
- Se clasifica información.
- Se cruza con frecuencia y recompra en SQL.

Impacto:

Acciones correctivas focalizadas.

3.4.4 Caso de Uso 4: Gestión Inteligente de Agenda

Problema:

No-show y baja optimización de capacidad instalada.

Solución:

- Análisis de patrones de asistencia.
- Alertas previas al cliente.
- Ajuste dinámico de agenda.

Impacto:

Mayor productividad técnica.

3.5 Integración entre Capas

La arquitectura funciona bajo el siguiente flujo:

Fuentes → Landing Zone GCP → MongoDB (no estructurados) → Procesamiento

Python → SQL DWH → Power BI / Activación Marketing

La integración se realiza mediante identificadores comunes:

- ID_Cliente
- Teléfono normalizado
- Placa de vehículo
- Número de OT
- ID_Campaña

Esto garantiza consistencia entre capas.

3.6 Rol Estratégico del Ecosistema

La arquitectura no es un fin en sí mismo.

Su propósito es cerrar el ciclo:

Dato → Análisis → Decisión → Acción

Gracias a la integración con Google Ads y Google Analytics, la información no solo se visualiza, sino que se activa directamente en campañas digitales segmentadas.

Esto conecta Business Intelligence con ejecución comercial real.

3.7 Impacto Estratégico

La arquitectura habilita:

- Incremento en retención.
- Optimización de marketing.
- Mejor gestión de reputación.

- Segmentación avanzada.
- Evolución hacia Next Best Action.

Se evita sobredimensionar infraestructura, manteniendo un equilibrio entre sofisticación y viabilidad operativa.

Capítulo 4

4.1 Inteligencia Artificial Aplicada

Luego de consolidar el Data Warehouse, la arquitectura Cloud y la integración de datos no estructurados, el siguiente paso evolutivo del proyecto es la incorporación de modelos de Inteligencia Artificial (IA) orientados a incrementar la recurrencia de compra y activar decisiones comerciales personalizadas.

La IA no se implementa por sofisticación tecnológica, sino como herramienta estratégica para:

- Reducir abandono.
- Incrementar frecuencia.
- Mejorar ticket promedio.
- Optimizar la inversión en marketing.
- Maximizar el Customer Lifetime Value (CLV).

La Inteligencia Artificial se integra como una capa incremental sobre la infraestructura BI existente, fortaleciendo el modelo financiero previamente consolidado en la Semana 5.

4.2 Relación con Indicadores Estratégicos

TABLA 4 ESCENARIO REALISTA – IMPACTO FINANCIERO

Indicador BI	Aporte del Modelo Predictivo
Retención	Predice abandono antes de que ocurra
Frecuencia	Detecta patrones de visita
Recompra	Estima probabilidad futura

CLV	Proyecta valor económico del cliente
NPS	Identifica clientes en riesgo
ROMI	Optimiza campañas antes de ejecutarlas

Nota. Elaboración propia con base en datos internos del proyecto

La IA amplifica la capacidad del BI al transformar análisis descriptivo en anticipación estratégica.

4.3 Objetivo Estratégico de la IA

El foco principal del modelo predictivo es:

Incrementar la recurrencia de compra mediante acciones automatizadas basadas en comportamiento histórico, señales digitales y patrones de consumo.

Este objetivo se alinea directamente con el Business Case consolidado y fortalece la sostenibilidad financiera del negocio.

4.4 Impacto Operativo Proyectado

TABLA 5 SENSIBILIDAD DEL MODELO

Variable	Actual	Con IA	Variación
Cientes mensuales	220	242	+10%
Ticket promedio	90	96	+6%
Frecuencia anual	1,3	1,45	+0,15

Nota. Elaboración propia con base en datos internos del proyecto

La IA impacta tres variables críticas:

1. Afluencia mensual (+10%).

2. Ticket promedio (+6%).
3. Frecuencia anual (+0,15).

Estas mejoras fortalecen directamente la recurrencia y elevan el valor económico del cliente.

4.5 Impacto en Ingresos

Ingreso mensual actual:

$$220 \times 90 = \text{USD } 19.800$$

Ingreso mensual proyectado:

$$242 \times 96 = \text{USD } 23.232$$

Incremento mensual bruto:

$$\text{USD } 3.432$$

Incremento anual bruto aproximado:

$$\text{USD } 41.184$$

Este incremento representa el efecto comercial directo antes de aplicar margen operativo.

4.6 Impacto en Margen (30% Oficial del Proyecto)

Margen incremental mensual:

$$3.432 \times 30\% \approx \text{USD } 1.030$$

Margen incremental anual:

$$1.030 \times 12 \approx \text{USD } \mathbf{12.360}$$

Este valor representa el beneficio económico real atribuible a la fase IA.

4.7 ROI Incremental de la IA

TABLA 6 . IMPACTO PROYECTADO DE LA INTELIGENCIA ARTIFICIAL

Concepto	Valor
Beneficio anual incremental	USD 12.360
Inversión específica IA	USD 3.500
ROI IA incremental	253%
Payback estimado	< 4 meses

Nota. Elaboración propia con base en datos internos del proyecto

El ROI del 253% indica que por cada dólar invertido en la fase IA, el negocio genera aproximadamente USD 2,53 adicionales de utilidad.

4.7.1 Aclaración metodológica clave

El ROI del 253% corresponde exclusivamente a la fase incremental de Inteligencia Artificial y está contenido dentro del Business Case global del proyecto (Semana 5). No representa duplicación de beneficios ni sustitución del ROI consolidado (173%–445%), sino un acelerador de los resultados proyectados.

4.8 Nota de Coherencia Metodológica

4.8.1 Relación entre Modelo Mensual y Modelo Anual

Las cifras operativas utilizadas en esta sección (220 clientes mensuales y ticket promedio de USD 90) corresponden a un análisis táctico del comportamiento comercial en horizonte mensual, cuyo propósito es dimensionar el impacto inmediato de la Inteligencia Artificial sobre afluencia y ticket promedio.

Estas cifras son plenamente coherentes con los supuestos financieros consolidados del Business Case global desarrollado en la Semana 5, el cual establece:

- 1.000 clientes activos anuales.
- Ingreso promedio anual por cliente: USD 1.000.

- Facturación anual estimada: USD 1.000.000.
- Margen operativo oficial: 30%.

El promedio mensual de 220 clientes refleja la dinámica operativa recurrente del negocio y, proyectado a nivel anual, resulta consistente con la base total de clientes activos considerada en el modelo estratégico.

Se distinguen, por tanto, dos niveles complementarios de análisis:

- **Nivel táctico mensual:** impacto operativo inmediato de la IA en afluencia y ticket.
- **Nivel estratégico anual:** consolidación financiera del proyecto dentro del Business Case global.

No existe contradicción entre ambos enfoques; el análisis mensual constituye una desagregación operativa del modelo anual consolidado. Esta precisión metodológica garantiza coherencia interna entre las semanas del proyecto y fortalece la robustez técnica del modelo ante evaluación académica.

4.9 Escenario Prudente (Sensibilidad)

TABLA 7 ROI INCREMENTAL DE LA FASE IA

Concepto	Resultado Estimado
Incremento mensual ingresos	≈ USD 1.600
Margen anual incremental	≈ USD 6.000 – 7.000
ROI estimado	70% – 100%

Nota. Elaboración propia con base en datos internos del proyecto

Incluso con impacto reducido al 50% del escenario proyectado, la fase IA sigue siendo financieramente viable.

Este análisis de sensibilidad demuestra que el modelo no depende de escenarios optimistas extremos para justificar su implementación.

Capítulo 5

5.1 Big Data y Activación en Tiempo Real

El objetivo de implementar un modelo de análisis en tiempo real es transformar la gestión del negocio de un enfoque reactivo hacia uno predictivo y accionable.

El sistema permite:

- Detectar señales tempranas de abandono.
- Activar campañas personalizadas automáticamente.
- Optimizar la frecuencia de visita.
- Maximizar el CLV.
- Mejorar el ROMI antes de ejecutar inversión publicitaria.

El modelo consolida la evolución completa del proyecto:

BI descriptivo → Analítica predictiva → Activación en tiempo real

Esta fase no reemplaza las anteriores; las integra y las potencia.

5.2 Problemática Inicial

Antes del proyecto:

- La pérdida de clientes se detectaba cuando ya había ocurrido.
- El marketing se ejecutaba sin predicción previa.
- La agenda operativa se gestionaba con información histórica.
- El NPS no se vinculaba con recompra ni retención.
- No existía automatización basada en comportamiento.

Esto generaba:

- Dependencia constante de captación.
- Subutilización de información digital.
- Decisiones comerciales parcialmente intuitivas.

- Pérdida de valor económico del cliente.

5.3 Fuentes de Datos (Consistentes con Semanas Previas)

5.3.1 Internas

TABLA 8 . ESCENARIO PRUDENTE – SENSIBILIDAD IA

Fuente	Uso Estratégico
Órdenes de trabajo	Frecuencia y abandono
Facturación	Ticket y margen
Historial de vehículo	Anticipación de mantenimiento
NPS	Señal de riesgo
Agenda	Planificación operativa

Nota. Elaboración propia con base en datos internos del proyecto

5.3.2 Digitales

TABLA 9 ESCENARIO CONSERVADOR – IMPACTO FINANCIERO PROYECTADO (10% INCREMENTO EN VENTAS)

Fuente	Aplicación
Perfil de Empresa en Google	Sensor de intención
WhatsApp Business	Seguimiento y conversión
Google Ads	Optimización ROMI

Nota. Elaboración propia con base en datos internos del proyecto

5.3.3 Externas

TABLA 10 FUENTES Y IMPACTOS

Fuente	Impacto
Datos sectoriales	Planeación estratégica
Indicadores macroeconómicos	Contextualización de demanda

Nota. Elaboración propia con base en datos internos del proyecto

Las fuentes no se seleccionan por volumen, sino por su capacidad predictiva y su aporte al valor económico del cliente.

5.4 Área de Aplicación Principal

El núcleo del modelo es la gestión estratégica del cliente como activo económico.

Impacta directamente en:

- Retención
- Frecuencia
- Recompra

- CLV
- ROMI

Departamentos implicados:

- Gerencia General
- Comercial y Marketing
- Atención al Cliente
- Finanzas
- Operaciones

El modelo es transversal y rompe silos funcionales.

5.5 Identificación de la Mejora Esperada

El análisis en tiempo real permite:

- ✓ Detectar abandono antes de que ocurra
- ✓ Anticipar mantenimientos por kilometraje
- ✓ Activar recordatorios personalizados
- ✓ Optimizar presupuesto de marketing
- ✓ Priorizar clientes de alto valor

Esto transforma la lógica del negocio:

De esperar que el cliente regrese

A gestionar activamente su recurrencia.

5.6 Business Case Final (Unificado y Coherente)

Se consolidan los supuestos financieros utilizados desde la Semana 5.

5.6.1 Supuestos Base Oficiales

TABLA 11 ROI INCREMENTAL DE LA FASE DE INTELIGENCIA ARTIFICIAL

Variable	Valor
Cientes activos anuales	1.000
Ingreso promedio anual por cliente	USD 1.000
Facturación anual estimada	USD 1.000.000
Margen operativo oficial	30%
Inversión anual total BI + IA	USD 11.306,49

Nota. Elaboración propia con base en datos internos del proyecto

✓ Se elimina definitivamente el valor USD 11.000.

- **Escenario Conservador (Impacto Integral 10%)**

Incremento ventas:

$$\text{USD } 1.000.000 \times 10\% = \text{USD } 100.000$$

Utilidad incremental (30%):

$$\text{USD } 30.000$$

ROI:

$$(30.000 - 11.306,49) / 11.306,49 \approx \mathbf{173\%}$$

Payback estimado: 4–5 meses

- **Escenario Realista (Impacto Integral 20%)**

Incremento ventas:

$$\text{USD } 200.000$$

Utilidad incremental (30%):

$$\text{USD } 60.000$$

$$\text{ROI} \approx \mathbf{445\%}$$

Payback estimado: 2–3 meses

5.7 Explicación Ejecutiva

En escenario conservador, el proyecto genera aproximadamente:

USD 2,7 de utilidad por cada dólar invertido.

En escenario realista:

Más de USD 5 por cada dólar invertido.

La viabilidad financiera es sólida y consistente con las fases previas del proyecto.

Aclaración metodológica:

La fase de IA (Semana 9) está contenida dentro de este Business Case global y actúa como acelerador del impacto proyectado, sin duplicar beneficios.

5.8 Impacto Estratégico Transversal

Más allá del ROI financiero, el modelo en tiempo real permite:

- Mayor previsibilidad de ingresos.
- Mejor planificación de agenda y capacidad instalada.
- Optimización dinámica del presupuesto de marketing.
- Reducción de decisiones reactivas.
- Consolidación de cultura data-driven.
- Ventaja competitiva sostenible.

El análisis en tiempo real no solo mejora ventas; mejora la calidad estructural de las decisiones.

Capítulo 6 CONCLUSIONES Y APLICACIONES

El desarrollo del modelo integral de Business Intelligence, Big Data e Inteligencia Artificial demuestra que la principal oportunidad de mejora en Oña Rodríguez Ingeniería Automotriz no radicaba en la falta de datos, sino en su limitada integración estratégica.

La consolidación de un Data Warehouse centrado en el cliente permitió transformar información operativa dispersa en inteligencia orientada a la toma de decisiones basada en evidencia.

El Business Case confirma la viabilidad financiera del proyecto, con un ROI estimado entre 173% y 445% y períodos de recuperación inferiores a cinco meses. La incorporación progresiva de Inteligencia Artificial fortalece estos resultados al impactar directamente en retención, frecuencia de visita y ticket promedio, actuando como acelerador del valor económico generado.

En términos aplicados, el modelo permite gestionar activamente la retención de clientes, optimizar la inversión en marketing mediante medición de ROMI, incrementar el Customer Lifetime Value y anticipar comportamientos de abandono. Asimismo, facilita una planificación financiera más predecible y reduce la dependencia de decisiones intuitivas.

En conclusión, el proyecto no representa únicamente una mejora tecnológica, sino una transformación estratégica hacia una cultura organizacional data-driven, fortaleciendo la sostenibilidad financiera y la competitividad de la empresa en el largo plazo.

Capítulo 7 REFERENCIAS BIBLIOGRÁFICAS

1. Ahumada, L., & Perusquia, J. (2016). *Inteligencia de negocios: Estrategias para la toma de decisiones empresariales*. Alfaomega.
2. Andícula Ríos, A. (2025). *Inteligencia artificial para el análisis del big data social de las plataformas digitales: Un estudio relacional para estrategias gerenciales de negocio* (Disertación doctoral, Universidad Ana G. Méndez – Gurabo). ProQuest Dissertations & Theses Global.
3. Asnate Salazar, E. J. (2025). *Métodos estadísticos asistidos con software: Aplicaciones en Python, Octave y R*. Editorial Mar Caribe.
4. Barroso-Moreno, C., Rayon-Rumayor, L., García-Vera, A., & Bautista, A. (2023). Big data and business intelligence on Twitter and Instagram for digital inclusion. *Comunicar*, 31(74), 45–56.
5. Casas Roma, J., Nin Guerrero, J., & Julbe López, F. (2019). *Big data: Análisis de datos en entornos masivos*. Editorial UOC.
6. Cesano, C. (2025). *La optimización de la industria de la traducción a través de la inteligencia artificial: Herramientas y procesos innovadores* (Tesis de maestría, Universidad Católica de Córdoba). ProQuest Dissertations & Theses Global.
7. Curto Díaz, J. (2016). *Introducción al business intelligence* (Nueva ed. rev. y amp.). Editorial UOC.
8. Darías Pérez, S. (2025). El impacto de la IA en la toma de decisiones empresariales. *Intelequia*. <https://intelequia.com/es/blog/post/el-impacto-de-la-ia-en-la-toma-de-decisiones-empresariales>

9. Davenport, T. H., & Harris, J. G. (2007). *Competing on analytics: The new science of winning*. Harvard Business School Press.
10. DOMO, Inc. (s. f.). *Business intelligence (BI): Conceptos y componentes*. <https://www.domo.com/learn/article/business-intelligence-components>
11. Fernández, E. P. (Coord.). (2016). *Big data: Eje estratégico en la industria audiovisual*. Editorial UOC.
12. García-Alsina, M. (2017). *Big data: Gestión y explotación de grandes volúmenes de datos*. Editorial UOC.
13. García-Morales, V. J., & Martín-Rojas, R. (2019). *Transformación digital e inteligencia artificial en la empresa*. Pirámide.
14. Hernández-Sánchez, B. R., Sánchez García, J. C., & Cardella, G. M. (Eds.). (2023). *Emprendimiento, sostenibilidad e inteligencia artificial: Claves para una cultura organizacional*. Dykinson.
15. IL3 – Universidad de Barcelona. (s. f.). *10 conceptos básicos para entender el business intelligence del presente*. <https://www.il3.ub.edu/blog/10-conceptos-basicos-para-entender-el-business-intelligence-del-presente/>
16. Joyanes Aguilar, L. (2013). *Big data: Análisis de grandes volúmenes de datos en organizaciones*. Alfaomega.
17. Microsoft. (2025). *¿Qué es Power BI? Información general sobre componentes y ventajas*. Microsoft Learn. <https://learn.microsoft.com/es-es/power-bi/fundamentals/power-bi-overview>
18. Ngai, E. W. T., Xiu, L., & Chau, D. C. K. (2009). Application of data mining techniques in customer relationship management: A literature review and classification. *Expert Systems with Applications*, 36(2), 2592–2602.

19. Pérez López, C. (2015). *Business intelligence y minería de datos: Técnicas y herramientas para la toma de decisiones*. RA-MA Editorial.
20. Provost, F., & Fawcett, T. (2013). *Data science for business*. O'Reilly Media.
21. Serrano Cobos, J. (2014). *Inteligencia competitiva y estratégica: Gestión de la información para la toma de decisiones*. Editorial UOC.
22. Shawareh, S., Tawfiq Awamleh, F., Al Hibat, A., & Altarawneh, A. S. (2025). The role of green business strategy in enhancing digital marketing strategy for sustainable business intelligence. *International Review of Management and Marketing*, 15(3), 18–25.
23. Shmueli, G., Bruce, P. C., Yahav, I., Patel, N. R., & Lichtendahl Jr., K. C. (2017). *Data mining for business analytics: Concepts, techniques, and applications in Python*. Wiley.
24. Sinnexus Business Intelligence. (2014). *Business intelligence: Competir con información*. Editorial UOC.
25. Valencia, J. (2018). *Big data: Fundamentos y aplicaciones en las organizaciones*. Ecoe Ediciones.
26. Wamba, S. F., Gunasekaran, A., Akter, S., Ren, S. J. F., Dubey, R., & Childe, S. J. (2017). Big data analytics and firm performance: Effects of dynamic capabilities. *Journal of Business Research*, 70, 356–365.