

ANALÍTICA EMPRESARIAL

**ESTADÍSTICA, SISTEMAS Y
ESTRATEGIA COMPETITIVA**



Datos Publicación Internacional

Título: Analítica Empresarial: Estadística, Sistemas y Estrategia Competitiva

Compilador y Editor: Ing. Fabián Peñaherrera Larenas

Diseño de tapa: Akdemik

Corrección de Estilo: Akdemik

Formato: PDF

Páginas: 253 pág.

Tamaño: Carta

Requisitos de sistema: Adobe Acrobat Reader

Modo de acceso: World Wide Web

Radicación: 199779

ISBN: 978-9907-0-1844-8

Abril 2026 – Akdemik

Copyright © Akdemik

Copyright del texto © 2026 de Autores

Atención por WhatsApp al +593997868082



1ª. Edición. Año 2026. Editorial Akdemik

"El contenido de este libro, así como la exactitud y confiabilidad de los datos, son responsabilidad exclusiva de los autores. Se permite la descarga y el compartir la obra siempre que se dé el crédito correspondiente a los autores, pero no se permite modificar el contenido ni utilizarlo con fines comerciales."

ISBN: 978-9907-0-1844-8



9 789907 018448

Prohibida su reproducción por cualquier medio

Distribución gratuita

CAPÍTULO 1

Introducción a la analítica empresarial

Ronald Adriano Pauta Ríos

rpautar@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0009-0009-8789-2008>

1. Introducción

La transformación digital ha modificado de manera significativa la forma en que las organizaciones administran sus recursos, interactúan con sus clientes y toman decisiones. En este contexto, los datos se han convertido en uno de los activos estratégicos más importantes de las empresas. Sin embargo, disponer de grandes volúmenes de información no garantiza por sí mismo mejores resultados. El verdadero valor surge cuando los datos pueden ser organizados, procesados, analizados e interpretados para apoyar decisiones empresariales.

La **analítica empresarial**, conocida internacionalmente como *business analytics*, comprende un conjunto de métodos estadísticos, matemáticos y computacionales orientados a transformar datos en información y conocimiento útil para la toma de decisiones. Su importancia radica en que permite superar una gestión basada exclusivamente en experiencia, intuición o criterios subjetivos, incorporando evidencia cuantitativa en la planificación y evaluación de las organizaciones.

La literatura contemporánea vincula estrechamente la analítica con la toma de decisiones basada en datos. Poulouse et al. (2024) destacan que la combinación de *big data*, inteligencia artificial y herramientas analíticas está ampliando las posibilidades de utilización de información para resolver problemas empresariales y respaldar decisiones.

De esta manera, la analítica empresarial no debe entenderse únicamente como una herramienta tecnológica. Constituye un enfoque de gestión que integra **personas, procesos, datos, tecnologías y modelos analíticos** con el propósito de mejorar el desempeño organizacional.

2. Conceptualización de la analítica empresarial

La analítica empresarial puede definirse como el proceso sistemático mediante el cual una organización recopila, transforma, analiza e interpreta datos para generar información que facilite la toma de decisiones.

Puede representarse conceptualmente mediante la siguiente secuencia:

Datos → Información → Conocimiento → Decisión → Acción → Resultado

Los datos corresponden a registros elementales de las operaciones empresariales. Cuando estos son organizados y contextualizados se convierten en información. Posteriormente, el análisis permite generar conocimiento, que puede utilizarse para seleccionar alternativas de decisión y ejecutar acciones.

Este proceso introduce una diferencia fundamental entre **tener datos y generar valor con los datos**.

Por ejemplo, una empresa comercial puede registrar diariamente miles de transacciones. Conocer que durante un mes se realizaron 15.000 ventas constituye información descriptiva. Determinar qué productos explican el crecimiento, identificar los segmentos con mayor rentabilidad y predecir las ventas del próximo trimestre representa un nivel superior de análisis.

3. Evolución de la analítica empresarial

La evolución de la analítica empresarial se encuentra vinculada al desarrollo de los sistemas de información, la estadística, la informática, la inteligencia de negocios, el aprendizaje automático y, más recientemente, la inteligencia artificial.

Inicialmente, las organizaciones utilizaban principalmente sistemas destinados al registro de operaciones. Posteriormente surgieron sistemas de apoyo a las decisiones (*Decision Support Systems* o DSS), almacenes de datos (*data warehouses*) y plataformas de inteligencia de negocios.

La literatura ha establecido una relación estrecha entre los sistemas de apoyo a decisiones y la inteligencia y analítica de negocios, dado que ambos buscan transformar datos y análisis en conocimiento útil para mejorar las decisiones organizacionales.

La evolución puede resumirse como:

Etapas	Característica principal
Sistemas transaccionales	Registro de operaciones
Sistemas de información gerencial	Elaboración de informes
Sistemas de apoyo a decisiones	Análisis de alternativas
Business Intelligence	Indicadores y visualización
Business Analytics	Modelos estadísticos y predictivos
Big Data Analytics	Procesamiento masivo de datos
Machine Learning	Aprendizaje basado en datos
Inteligencia artificial	Automatización y apoyo inteligente
IA generativa	Generación y síntesis de información

4. Del dato a la decisión empresarial

Uno de los principales desafíos organizacionales consiste en convertir datos dispersos en información relevante.

El proceso puede representarse mediante seis etapas:

1. Captura de datos



2. Almacenamiento



3. Preparación y depuración



4. Análisis



5. Interpretación



6. Toma de decisiones

La calidad de este proceso es fundamental. Datos incompletos, inconsistentes o desactualizados pueden producir análisis incorrectos y, por consiguiente, decisiones equivocadas.

Precisamente, las metodologías modernas de minería de datos conceden considerable importancia a la comprensión y preparación de los datos antes de desarrollar modelos. En CRISP-DM, por ejemplo, el ciclo comprende comprensión del negocio, comprensión de los datos, preparación, modelado, evaluación y despliegue.

5. Tipos de analítica empresarial

Uno de los modelos más utilizados para comprender la analítica empresarial consiste en clasificarla en cuatro niveles:

5.1. Analítica descriptiva

Responde fundamentalmente:

¿Qué ocurrió?

Utiliza información histórica para describir el comportamiento de la organización.

Algunas herramientas son:

- tablas de frecuencia;
- estadística descriptiva;
- indicadores;
- dashboards;
- gráficos;
- análisis de tendencias.

Por ejemplo, una empresa puede determinar:

- ventas mensuales;
- productos más vendidos;
- número de clientes;
- ticket promedio;
- rotación de inventarios;

- rentabilidad por producto.

Un indicador básico de crecimiento puede expresarse como:

$$TC = \frac{V_t - V_{t-1}}{V_{t-1}} \times 100$$

donde:

TC = tasa de crecimiento;

V_t = ventas del período actual;

V_{t-1} = ventas del período anterior.

6. Analítica diagnóstica

La analítica diagnóstica busca responder:

¿Por qué ocurrió?

Su finalidad consiste en identificar relaciones, patrones y posibles factores asociados con un determinado resultado.

Puede utilizar:

- correlaciones;
- tablas cruzadas;
- análisis de varianza;
- regresión;
- análisis de causas;
- segmentación;
- análisis multidimensional.

Supóngase que las ventas de una organización disminuyeron 12 %. La analítica descriptiva permite detectar la reducción, mientras que la analítica diagnóstica intenta identificar las razones.

Podría determinarse, por ejemplo, que la reducción se relaciona con:

Ventas ↓

- menor número de clientes
- reducción de publicidad
- incremento del precio
- aparición de competidores
- problemas de inventario.

La combinación de diferentes fuentes de información permite construir explicaciones más completas del comportamiento empresarial.

7. Analítica predictiva

La analítica predictiva responde:

¿Qué probablemente ocurrirá?

Utiliza información histórica para estimar acontecimientos futuros.

Entre las técnicas utilizadas se encuentran:

- regresión lineal;
- regresión logística;
- árboles de decisión;
- series temporales;
- redes neuronales;
- random forest;
- gradient boosting;
- máquinas de vectores de soporte.

Una regresión lineal puede representarse como:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \epsilon$$

donde Y representa la variable que se desea predecir y $X_1, \dots, X_k$ los factores utilizados como predictores.

En un contexto empresarial podría plantearse:

$$Ventas = \beta_0 + \beta_1(Publicidad) + \beta_2(Precio) + \beta_3(Promociones) + \epsilon$$

El objetivo no consiste únicamente en explicar las ventas pasadas, sino en estimar su comportamiento bajo determinadas condiciones futuras.

8. Analítica prescriptiva

Representa un nivel avanzado y responde:

¿Qué debería hacer la organización?

Utiliza resultados descriptivos y predictivos conjuntamente con técnicas de optimización y simulación.

Puede incorporar:

- programación lineal;
- simulación;
- optimización;

- algoritmos heurísticos;
- inteligencia artificial;
- sistemas de recomendación.

Por ejemplo, una organización podría utilizar información sobre demanda futura para decidir simultáneamente:

- cuánto producir;
- cuánto comprar;
- dónde almacenar;
- qué precio establecer;
- qué clientes priorizar;
- cuánto invertir en publicidad.

Por tanto:

Descriptiva → ¿Qué pasó?

Diagnóstica → ¿Por qué pasó?

Predictiva → ¿Qué pasará?

Prescriptiva → ¿Qué debemos hacer?

9. Analítica empresarial y estadística

La estadística constituye uno de los fundamentos de la analítica empresarial. Permite organizar datos, identificar patrones, cuantificar relaciones y realizar inferencias.

Black (2024) vincula directamente la estadística empresarial con las técnicas de *business analytics* y la toma de decisiones cuantitativas basada en información.

Entre las principales herramientas estadísticas utilizadas en empresas se encuentran:

Herramienta	Aplicación
Media	Comportamiento promedio
Mediana	Valor central
Desviación estándar	Variabilidad
Correlación	Asociación
Regresión	Explicación y predicción
Pruebas de hipótesis	Contraste de decisiones
Series temporales	Pronósticos
Clustering	Segmentación

La estadística proporciona así una transición entre los datos observados y la construcción de modelos analíticos.

10. Business Intelligence y Business Analytics

Aunque suelen utilizarse indistintamente, existen diferencias conceptuales entre **Business Intelligence (BI)** y **Business Analytics (BA)**.

Business Intelligence se orienta principalmente hacia:

- almacenamiento;
- integración;
- visualización;
- dashboards;
- indicadores;
- reportes.

Business Analytics incorpora:

- estadística avanzada;
- minería de datos;
- aprendizaje automático;
- modelos predictivos;
- optimización.

Por ejemplo:

BI: Las ventas disminuyeron 8 %.

BA: La probabilidad de que las ventas continúen disminuyendo durante el próximo trimestre es elevada.

Analítica prescriptiva: Para revertir la tendencia debería modificarse la estrategia comercial en determinados segmentos.

La integración de BI y BA permite pasar de la observación de resultados hacia la generación de conocimiento accionable.

11. Indicadores clave de desempeño

Los **Key Performance Indicators (KPI)** permiten medir el desempeño de áreas estratégicas.

Algunos indicadores empresariales frecuentes son:

Rentabilidad

$$ROA = \frac{Utilidad\ neta}{Activos\ totales} \times 100$$

Margen de utilidad

$$MU = \frac{Utilidad\ neta}{Ventas} \times 100$$

Rotación de inventario

$$RI = \frac{Costo\ de\ ventas}{Inventario\ promedio}$$

Ticket promedio

$$TP = \frac{Ventas\ totales}{Numero\ de\ transacciones}$$

Tasa de conversión

$$TC = \frac{Clientes\ que\ compran}{Visitantes} \times 100$$

La elección del KPI debe guardar relación directa con los objetivos estratégicos de la organización.

12. Analítica y minería de datos

La minería de datos permite descubrir patrones previamente desconocidos dentro de grandes conjuntos de información.

Entre sus principales tareas se encuentran:

Clasificación: asignar observaciones a categorías.

Regresión: predecir variables continuas.

Clustering: identificar grupos similares.

Reglas de asociación: descubrir relaciones entre productos o comportamientos.

Detección de anomalías: identificar operaciones atípicas.

Un proyecto empresarial de minería de datos puede estructurarse mediante CRISP-DM:

1. comprensión del negocio;
2. comprensión de los datos;
3. preparación de los datos;
4. modelado;
5. evaluación;

6. despliegue.

IBM señala que estas etapas conforman un ciclo flexible y que los proyectos pueden regresar a etapas anteriores conforme aparecen nuevos hallazgos.

Este enfoque es particularmente importante porque obliga a comenzar por el **problema empresarial** y no por el algoritmo.

13. Aplicaciones funcionales de la analítica

La analítica empresarial puede utilizarse transversalmente.

Área	Aplicaciones
Marketing	Segmentación y campañas
Ventas	Pronóstico de ventas
Finanzas	Riesgo financiero
Talento humano	Rotación de empleados
Producción	Optimización
Logística	Rutas e inventarios
Servicio	Predicción de abandono
Medio ambiente	Indicadores ambientales
Dirección	Planificación estratégica

Por ejemplo, en marketing puede estimarse la probabilidad de compra; en finanzas, la probabilidad de incumplimiento crediticio; y en recursos humanos, la probabilidad de abandono de un empleado.

14. Analítica del comportamiento del cliente

Una de las áreas de mayor aplicación es el análisis de clientes.

La empresa puede combinar información sobre:

- edad;
- ubicación;
- frecuencia de compra;
- monto comprado;
- categorías preferidas;
- respuestas a promociones;
- interacciones digitales.

Una técnica particularmente útil es el análisis RFM:

$$RFM = f(R, F, M)$$

donde:

R = Recency: tiempo transcurrido desde la última compra.

F = Frequency: frecuencia de compras.

M = Monetary: valor monetario comprado.

Este procedimiento permite identificar clientes de alto valor, clientes frecuentes, compradores recientes y clientes en riesgo de abandono.

15. Calidad y gobierno de los datos

Un modelo analítico no puede compensar completamente datos de baja calidad.

La calidad de los datos puede evaluarse mediante dimensiones como:

- exactitud;
- integridad;
- consistencia;
- actualidad;
- unicidad;
- relevancia.

Puede conceptualizarse:

$$\text{Calidad del dato} = f(E, I, C, A, U, R)$$

La preparación de datos constituye por ello una etapa crítica. IBM destaca que esta fase incluye limpieza, transformación, integración y agregación de información antes de aplicar algoritmos analíticos.

La organización debe establecer además mecanismos de gobierno que definan quién captura, administra, modifica, utiliza y protege los datos.

16. Inteligencia artificial y analítica empresarial

La inteligencia artificial amplía significativamente las capacidades tradicionales de análisis.

Actualmente es posible utilizar IA para:

- clasificación automática;
- pronósticos;
- detección de fraude;
- análisis de textos;
- recomendación de productos;

- reconocimiento de patrones;
- asistentes empresariales;
- automatización de reportes.

Sin embargo, la adopción de IA introduce riesgos relacionados con transparencia, sesgo, privacidad, seguridad y confiabilidad.

El **AI Risk Management Framework** de NIST propone que las organizaciones gestionen estos riesgos durante todo el ciclo de vida de los sistemas de IA mediante cuatro funciones principales: **gobernar, mapear, medir y gestionar**.

Por ello, la incorporación de inteligencia artificial a la analítica empresarial debe combinar desempeño tecnológico con mecanismos de control y responsabilidad.

17. Cultura organizacional basada en datos

Una organización *data-driven* no es simplemente aquella que posee bases de datos.

Es aquella en la cual las decisiones relevantes incorporan sistemáticamente evidencia.

Puede representarse mediante:

$$\textit{Organización Data-Driven} = \textit{Datos} + \textit{Tecnología} + \textit{Personas} + \textit{Procesos} + \textit{Cultura}$$

La ausencia de cualquiera de estos elementos limita el impacto de la analítica.

Una empresa puede adquirir tecnologías avanzadas y fracasar en su transformación analítica si sus directivos continúan tomando decisiones sin utilizar los resultados generados.

La cultura de datos requiere, por tanto:

- liderazgo;
- alfabetización de datos;
- infraestructura;
- gobernanza;
- competencias analíticas;
- comunicación;
- experimentación;
- evaluación continua.

18. Caso aplicado

Considérese una empresa comercial que dispone de información sobre 10.000 clientes.

Las variables son:

Variable	Descripción
Edad	Edad del cliente
Ingreso	Ingreso mensual
Frecuencia	Compras mensuales
Ticket	Compra promedio
Antigüedad	Meses como cliente
Promociones	Promociones utilizadas
Compra	Compró/no compró

La organización desea responder cuatro preguntas.

Pregunta 1: ¿Qué está ocurriendo?

Mediante analítica descriptiva calcula ventas, frecuencia de compra y ticket promedio.

Pregunta 2: ¿Por qué algunos clientes compran más?

Utiliza correlaciones, segmentación y regresión.

Pregunta 3: ¿Quién comprará nuevamente?

Construye modelos predictivos utilizando regresión logística, árboles de decisión o redes neuronales.

Pregunta 4: ¿A quién debería dirigirse la próxima campaña?

Selecciona los clientes con mayor probabilidad de compra y mayor valor económico esperado.

El proceso completo transforma:

Datos → patrón → predicción → decisión → acción comercial.

19. Proceso propuesto de analítica empresarial

A partir de los principios analizados, puede plantearse el siguiente modelo:

Problema empresarial

↓

Objetivo analítico

↓

Identificación de datos

↓

Preparación

↓

Análisis exploratorio

↓

Modelado

↓

Evaluación

↓

Interpretación empresarial

↓

Decisión

↓

Implementación

↓

Evaluación del resultado

Esta estructura es compatible con el enfoque CRISP-DM, que recomienda comenzar definiendo los objetivos empresariales y los criterios con los cuales se evaluará el éxito del proyecto.

20. Desafíos actuales de la analítica empresarial

La implementación de sistemas analíticos enfrenta múltiples desafíos.

Uno de ellos corresponde a la **calidad de los datos**. Un segundo problema es la falta de competencias analíticas dentro de las organizaciones. A ello se suman dificultades de integración tecnológica, privacidad, seguridad, resistencia al cambio y falta de alineación entre proyectos analíticos y objetivos estratégicos.

Con el crecimiento de la inteligencia artificial se incorporan nuevos desafíos relacionados con:

sesgos → explicabilidad → transparencia → privacidad → seguridad → responsabilidad.

El NIST AI RMF plantea precisamente que la gestión del riesgo asociado con inteligencia artificial debe integrarse de manera continua a todo el ciclo de vida de los sistemas.

Esto implica que el éxito de la analítica empresarial no debe evaluarse únicamente mediante precisión estadística.

Un modelo puede alcanzar 95 % de exactitud y aun así generar escaso valor empresarial si no resuelve un problema relevante.

Por consiguiente:

Éxito analítico ≠ únicamente precisión

sino:

Éxito analítico = Precisión + Utilidad + Interpretabilidad + Impacto

21. Tendencias de la analítica empresarial

Durante los próximos años la analítica empresarial continuará evolucionando mediante la integración de:

- inteligencia artificial;
- IA generativa;
- aprendizaje automático automatizado;
- analítica en tiempo real;
- procesamiento de lenguaje natural;
- análisis de grandes volúmenes de datos;
- sistemas de recomendación;
- automatización de decisiones;
- modelos explicables;
- analítica aumentada.

Especial atención merece la IA generativa. El NIST publicó en 2024 un perfil específico complementario a su marco de gestión de riesgos para abordar los riesgos particulares asociados con sistemas de IA generativa.

La tendencia apunta hacia sistemas en los cuales los responsables empresariales puedan interactuar directamente con los datos mediante lenguaje natural.

Por ejemplo:

“¿Por qué disminuyeron las ventas de la región Costa durante agosto?”

Un sistema analítico podría integrar bases de datos, identificar variaciones, generar gráficos, localizar factores asociados y elaborar una explicación ejecutiva.

22. Conclusiones

La analítica empresarial representa una evolución fundamental en la manera en que las organizaciones utilizan la información. Su propósito no consiste simplemente en acumular datos, sino en transformarlos en conocimiento capaz de apoyar decisiones estratégicas, tácticas y operativas.

La transición desde analítica descriptiva hacia analítica diagnóstica, predictiva y prescriptiva permite incrementar progresivamente la capacidad de una empresa para comprender su desempeño, anticipar escenarios y seleccionar cursos de acción.

Asimismo, la expansión del aprendizaje automático y la inteligencia artificial está modificando las capacidades analíticas tradicionales. Sin embargo, estas tecnologías deben implementarse conjuntamente con prácticas adecuadas de calidad, gobernanza, seguridad y gestión de riesgos.

En consecuencia, una organización verdaderamente orientada por datos requiere integrar capacidades tecnológicas, estadísticas y gerenciales. La analítica empresarial debe entenderse como un proceso continuo en el cual **los datos generan información, la información genera conocimiento y el conocimiento se transforma en decisiones que producen valor empresarial.**

Referencias bibliográficas

Autio, C., Schwartz, R., Dunietz, J., Jain, S., Stanley, M., Tabassi, E., Hall, P., & Roberts, K. (2024). *Artificial intelligence risk management framework: Generative artificial intelligence profile* (NIST AI 600-1). National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.AI.600-1>

Black, K. (2024). *Business statistics: For contemporary decision making* (11th ed.). Wiley.

IBM. (2026). *CRISP-DM help overview*. IBM Documentation.

IBM. (2026). *Data preparation in the mining process*. IBM Documentation.

National Institute of Standards and Technology. (2023). *Artificial intelligence risk management framework (AI RMF 1.0)* (NIST AI 100-1). U.S. Department of Commerce. <https://doi.org/10.6028/NIST.AI.100-1>

Poulose, J., Sharma, V., & Maheshkar, C. (Eds.). (2024). *Data-driven decision making*. Springer.

CAPÍTULO 2

Estadística para la gestión operacional

Georgina Janeth Encalada Tenorio

gencalada@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0000-0002-8081-7330>

Carlos Alfredo Cevallos Monar

acevallos@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0000-0002-6751-6998>

1. Introducción

La gestión operacional comprende el conjunto de actividades mediante las cuales las organizaciones planifican, organizan, controlan y mejoran los procesos utilizados para producir bienes o prestar servicios. Dentro de este contexto, la estadística constituye una herramienta fundamental porque permite transformar datos provenientes de las operaciones en información útil para evaluar el desempeño, detectar problemas, reducir la variabilidad y respaldar decisiones.

Las empresas generan continuamente información relacionada con producción, inventarios, tiempos de entrega, productividad, costos, calidad, atención al cliente y utilización de recursos. Cuando estos datos son analizados adecuadamente, es posible identificar patrones, comparar resultados, anticipar necesidades y diseñar acciones de mejora.

La estadística aplicada a las operaciones no debe limitarse al cálculo de promedios o porcentajes. Su verdadero potencial radica en proporcionar métodos para **describir, explicar, inferir, controlar y predecir el comportamiento de los procesos empresariales**. Montgomery (2020) señala que los métodos estadísticos de control de calidad tienen aplicaciones tanto en organizaciones industriales como en actividades de servicios y permiten caracterizar, controlar y mejorar sistemáticamente los procesos.

En consecuencia, la relación entre estadística y gestión operacional puede sintetizarse mediante:

*Datos operacionales → Análisis estadístico → Información → Decisión
→ Mejora del proceso*

El presente capítulo desarrolla los principales fundamentos estadísticos que pueden aplicarse en la gestión operacional, incluyendo estadística descriptiva, medidas de variabilidad, probabilidades, muestreo, inferencia, correlación, regresión, pronósticos, control estadístico de procesos, capacidad de procesos e indicadores operacionales.

2. Estadística y gestión operacional

La estadística puede definirse como el conjunto de métodos destinados a recopilar, organizar, analizar e interpretar datos para apoyar la comprensión de fenómenos y la toma de decisiones.

Dentro de una organización, estos procedimientos pueden aplicarse a diferentes interrogantes:

- ¿Cuánto produce diariamente una planta?
- ¿Cuál es el tiempo promedio de atención?
- ¿Cuánto varía la demanda semanal?
- ¿Qué porcentaje de productos presenta defectos?
- ¿Existe relación entre capacitación y productividad?
- ¿La reducción del tiempo de entrega es estadísticamente significativa?
- ¿Cuánto deberá producirse durante el próximo mes?

Por esta razón, la estadística representa uno de los pilares de la gestión basada en datos.

Podemos expresar conceptualmente:

$$Gestión\ operativa = f(D, a, t, os, Procesos, Recursos, Decisiones)$$

La estadística interviene principalmente en la transformación de datos operacionales en evidencia para decidir.

3. Tipos de estadística aplicados a las operaciones

La estadística puede dividirse en dos grandes áreas:

3.1. Estadística descriptiva

La estadística descriptiva permite organizar, resumir y presentar los datos observados.

Entre sus principales herramientas se encuentran:

- tablas;
- distribuciones de frecuencia;
- gráficos;
- media;
- mediana;
- moda;
- rango;
- varianza;
- desviación estándar;
- coeficiente de variación.

Por ejemplo, una empresa puede analizar el tiempo de entrega de sus pedidos durante un mes.

Si los tiempos registrados fueron:

3, 4, 4, 5, 5, 5, 6, 6, 7, 8

es posible calcular indicadores para resumir el comportamiento del proceso.

3.2. Estadística inferencial

La estadística inferencial permite utilizar información procedente de una muestra para realizar conclusiones sobre una población.

Sus principales técnicas incluyen:

- estimación de parámetros;
- intervalos de confianza;
- pruebas de hipótesis;
- análisis de varianza;
- correlación;
- regresión.

En gestión operacional resulta particularmente útil porque no siempre es posible analizar todos los productos, clientes, transacciones o procesos.

Por ejemplo, una fábrica produce 100.000 unidades mensuales. Analizar cada unidad puede resultar costoso, por lo cual se selecciona una muestra representativa.

Así:

Población → Muestra → Análisis → Inferencia

4. Variables utilizadas en la gestión operacional

Antes de aplicar un método estadístico es fundamental identificar el tipo de variable.

4.1. Variables cualitativas

Representan categorías.

Ejemplos:

- proveedor;
- tipo de producto;
- turno;
- estado del pedido;
- tipo de defecto;

- nivel de satisfacción.

Pueden clasificarse en:

Nominales: no existe un orden natural.

Ejemplo:

$$\textit{Proveedor} = A, B, C$$

Ordinales: poseen un orden.

Ejemplo:

$$\textit{Bajo} < \textit{Medio} < \textit{Alto}$$

5. Variables cuantitativas

Representan cantidades numéricas.

5.1. Variables discretas

Surgen del conteo.

Ejemplos:

- número de productos defectuosos;
- número de pedidos;
- número de trabajadores;
- número de devoluciones.

5.2. Variables continuas

Proviene de mediciones.

Ejemplos:

- peso;
- temperatura;
- tiempo;
- costo;
- distancia;
- volumen.

Distinguir correctamente la naturaleza de las variables permite seleccionar el procedimiento estadístico adecuado.

6. Medidas de tendencia central

Las medidas de tendencia central indican alrededor de qué valor se concentran las observaciones.

6.1. Media aritmética

La media se calcula mediante:

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$$

Supóngase que una empresa registra las siguientes unidades producidas durante cinco días:

100, 110, 105, 115, 120

Entonces:

$$\bar{x} = \frac{100 + 110 + 105 + 115 + 120}{5}$$
$$\bar{x} = 110$$

La producción promedio es de **110 unidades diarias**.

7. Mediana

La mediana corresponde al valor central después de ordenar las observaciones.

Considérese:

20, 22, 23, 25, 80

La media sería:

$$\bar{x} = 34$$

Sin embargo, la mediana es:

$$Me = 23$$

El valor 80 incrementa considerablemente la media. En estos casos, la mediana puede representar mejor el comportamiento típico.

Esto resulta particularmente importante en variables como:

- salarios;
- tiempos de espera;
- montos de compra;
- duración de procesos;
- costos extraordinarios.

8. Moda

La moda representa el valor que aparece con mayor frecuencia.

Por ejemplo:

$$A, A, A, B, B, C$$

La moda es:

$$Mo = A$$

En operaciones puede utilizarse para identificar:

- producto más vendido;
- defecto más frecuente;
- turno con mayor número de incidencias;
- método de pago predominante.

9. Medidas de dispersión

Dos procesos pueden tener el mismo promedio pero comportamientos completamente diferentes.

Considérese:

Proceso A

$$99, 100, 100, 100, 101$$

Proceso B

$$80, 90, 100, 110, 120$$

Ambos presentan una media de aproximadamente 100, pero el segundo proceso posee mucha mayor variabilidad.

Por ello, la gestión operacional debe analizar simultáneamente:

$$\text{Nivel promedio} + \text{Variabilidad}$$

10. Rango

El rango corresponde a:

$$R = X_{max} - X_{min}$$

Para:

$$80, 90, 100, 110, 120$$

se obtiene:

$$R = 120 - 80 = 40$$

Es una medida sencilla, aunque únicamente considera los valores extremos.

11. Varianza

La varianza muestral se calcula mediante:

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1}$$

Permite cuantificar cuánto se alejan, en promedio cuadrático, las observaciones de la media.

Una mayor varianza indica mayor dispersión.

12. Desviación estándar

La desviación estándar corresponde a:

$$s = \sqrt{s^2}$$

Su principal ventaja es que conserva las mismas unidades de la variable original.

Si el tiempo promedio de atención es:

$$\bar{x} = 15 \text{ minutos}$$

y:

$$s = 2 \text{ minutos}$$

el proceso es considerablemente más estable que otro con:

$$\bar{x} = 15, s = 8$$

Por esta razón, la reducción de variabilidad constituye un objetivo fundamental de la gestión de operaciones y del control estadístico de calidad.

13. Coeficiente de variación

Permite comparar la variabilidad relativa entre variables o procesos que poseen diferentes medias.

$$CV = \frac{s}{\bar{x}} \times 100$$

Por ejemplo:

Proceso A

$$\bar{x} = 100, s = 5$$
$$CV_A = 5\%$$

Proceso B

$$\bar{x} = 50, s = 5$$
$$CV_B = 10\%$$

Aunque ambos tienen igual desviación estándar, el proceso B presenta mayor variabilidad relativa.

14. Distribuciones de probabilidad

La probabilidad constituye un componente esencial para trabajar con incertidumbre.

En operaciones puede utilizarse para estimar:

- demanda;
- tiempos de llegada;
- número de defectos;
- fallas;
- duración de actividades;
- riesgos operacionales.

Entre las distribuciones más frecuentes se encuentran:

Distribución	Aplicación
Binomial	Productos conformes/no conformes
Poisson	Número de eventos
Normal	Variables continuas
Exponencial	Tiempo entre eventos
Uniforme	Valores igualmente probables

15. Distribución binomial

La distribución binomial es apropiada cuando existen dos resultados posibles:

Éxito/Fracaso

Por ejemplo:

Producto conforme/Producto defectuoso

Su probabilidad puede calcularse mediante:

$$P(X = x) = \binom{n}{x} p^x (1 - p)^{n-x}$$

donde:

- n : número de ensayos;
- x : número de éxitos;
- p : probabilidad de éxito.

Si una empresa sabe que el 5 % de sus productos presenta defectos, esta distribución puede utilizarse para estimar cuántas unidades defectuosas podrían encontrarse dentro de una muestra.

16. Distribución de Poisson

Se utiliza para modelar la cantidad de eventos registrados dentro de un intervalo.

$$P(X = x) = \frac{e^{-\lambda} \lambda^x}{x!}$$

Puede aplicarse a:

- clientes que llegan por hora;
- accidentes por mes;
- fallas por semana;
- reclamos diarios;
- llamadas recibidas.

Por ejemplo, si una empresa recibe en promedio:

$$\lambda = 5$$

reclamos diarios, puede estimarse la probabilidad de recibir exactamente siete.

17. Distribución normal

La distribución normal es una de las herramientas más importantes de la estadística.

Su comportamiento está determinado principalmente por:

$$\mu = \text{media}$$

y

σ = desviación estándar

Muchas variables operacionales pueden aproximarse a una distribución normal bajo determinadas condiciones.

Ejemplos:

- pesos;
- dimensiones;
- tiempos;
- consumos;
- rendimientos.

La estandarización permite calcular:

$$Z = \frac{X - \mu}{\sigma}$$

Con ello puede determinarse qué tan lejos se encuentra una observación respecto a la media en unidades de desviación estándar.

18. Muestreo en la gestión operacional

El muestreo consiste en seleccionar una parte de la población para obtener información sobre ella.

Entre los métodos probabilísticos se encuentran:

- muestreo aleatorio simple;
- sistemático;
- estratificado;
- por conglomerados.

Por ejemplo, si una empresa produce:

$$N = 50.000$$

productos mensuales, puede seleccionar una muestra para evaluar la calidad sin inspeccionar la totalidad.

Una fórmula básica para población finita es:

$$n = \frac{NZ^2pq}{e^2(N-1) + Z^2pq}$$

donde:

- N : población;
- Z : valor de confianza;
- p : probabilidad esperada;
- $q = 1 - p$;
- e : margen de error.

19. Intervalos de confianza

Un intervalo de confianza permite estimar un parámetro poblacional mediante un rango.

Para la media:

$$IC = \bar{x} \pm Z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$$

Supóngase:

$$\begin{aligned}\bar{x} &= 30 \\ \sigma &= 5 \\ n &= 100\end{aligned}$$

Para un nivel de confianza del 95 %:

$$\begin{aligned}IC &= 30 \pm 1.96 \frac{5}{10} \\ IC &= 30 \pm 0.98\end{aligned}$$

Por tanto:

$$29.02 \leq \mu \leq 30.98$$

La empresa puede afirmar, bajo los supuestos del procedimiento, que el promedio poblacional se encontraría dentro de ese intervalo con un nivel de confianza del 95 %.

20. Pruebas de hipótesis

Las pruebas de hipótesis permiten evaluar afirmaciones mediante evidencia estadística.

Su estructura básica comprende:

$$\begin{aligned}H_0 &= \text{Hipótesis nula} \\ H_1 &= \text{Hipótesis alternativa}\end{aligned}$$

Por ejemplo, una empresa introduce una nueva maquinaria y quiere comprobar si incrementó la producción.

Se podría plantear:

$$H_0: \mu_{\text{nuevo}} = \mu_{\text{anterior}}$$
$$H_1: \mu_{\text{nuevo}} > \mu_{\text{anterior}}$$

Si:

$$p < 0.05$$

se rechaza generalmente H_0 para un nivel de significación del 5 %.

Esta metodología evita atribuir automáticamente cualquier diferencia observada a una mejora real.

21. Comparación de dos procesos

Supóngase que una empresa quiere evaluar dos métodos de procesamiento.

Método	Tiempo promedio
A	25 min
B	21 min

La diferencia observada es:

$$25 - 21 = 4 \text{ minutos}$$

Sin embargo, esto no demuestra por sí mismo que el método B sea estadísticamente más rápido.

Una prueba de medias permite determinar si la diferencia puede atribuirse razonablemente al cambio de método o si podría explicarse por variación aleatoria.

22. Análisis de varianza

Cuando existen más de dos grupos puede utilizarse ANOVA.

Por ejemplo, una empresa opera con tres turnos:

Turno A, Turno B, Turno C

y desea determinar si la productividad media es diferente.

Las hipótesis son:

$$H_0: \mu_A = \mu_B = \mu_C$$
$$H_1: \text{al menos una media es diferente}$$

El estadístico utilizado es:

$$F = \frac{\text{Variabilidad entre grupos}}{\text{Variabilidad dentro de grupos}}$$

Si se detectan diferencias significativas, posteriormente pueden aplicarse comparaciones *post hoc* para determinar cuáles grupos difieren.

23. Correlación en operaciones

El coeficiente de correlación permite cuantificar la relación lineal entre dos variables.

El coeficiente de Pearson puede expresarse como:

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}}$$

Los valores se encuentran entre:

$$-1 \leq r \leq 1$$

Interpretativamente:

- valores próximos a 1: asociación positiva;
- valores próximos a -1 : asociación negativa;
- valores próximos a 0: poca asociación lineal.

24. Aplicación de correlación

Una empresa analiza capacitación y productividad.

Horas de capacitación	Producción
2	100
4	115
6	126
8	143
10	160

Si se obtiene:

$$r = 0.96$$

existe una asociación lineal positiva muy fuerte.

Sin embargo:

$$\text{Correlación} \neq \text{Causalidad}$$

La existencia de asociación no demuestra que una variable sea necesariamente la causa de la otra.

25. Regresión lineal

La regresión permite modelar la relación entre una variable dependiente y una o varias variables independientes.

En el caso simple:

$$Y = \beta_0 + \beta_1 X + \epsilon$$

Por ejemplo:

$$Producción' = \beta_0 + \beta_1 (Horas de trabajo) + \epsilon$$

Si el modelo estimado es:

$$Producción' = 50 + 8X$$

una hora adicional de trabajo se asocia, manteniendo las condiciones del modelo, con aproximadamente ocho unidades adicionales de producción.

26. Regresión múltiple

Cuando existen varios factores:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \epsilon$$

Una aplicación operacional podría plantearse como:

$$\begin{aligned} &Productividad \\ &= \beta_0 + \beta_1 (Capacitación) + \beta_2 (Experiencia) + \beta_3 (Tecnología) \\ &+ \beta_4 (Ausentismo) + \epsilon \end{aligned}$$

Este modelo permite analizar simultáneamente varios factores que podrían explicar el desempeño.

27. Coeficiente de determinación

El coeficiente:

$$R^2$$

indica la proporción de variabilidad de Y explicada por el modelo.

Por ejemplo:

$$R^2 = 0.72$$

indica que aproximadamente el 72 % de la variabilidad observada en la variable dependiente es explicada por los predictores incluidos, dentro del modelo considerado.

No obstante, un alto R^2 no garantiza que el modelo sea válido. También deben evaluarse:

- supuestos;
- significación;
- residuos;
- sobreajuste;
- capacidad predictiva.

28. Series temporales

Una serie temporal corresponde a observaciones ordenadas cronológicamente.

Por ejemplo:

Mes	Demanda
Enero	1.200
Febrero	1.250
Marzo	1.300
Abril	1.420
Mayo	1.470

El objetivo puede consistir en identificar:

- tendencia;
- estacionalidad;
- ciclos;
- irregularidad.

Conceptualmente:

$$Y_t = T_t + S_t + C_t + I_t$$

donde:

- T_t : tendencia;
- S_t : componente estacional;
- C_t : componente cíclico;
- I_t : componente irregular.

29. Pronósticos operacionales

Los pronósticos son esenciales para:

- producción;
- ventas;
- compras;
- contratación;
- inventarios;
- capacidad instalada;
- logística.

Un método sencillo es el promedio móvil:

$$\hat{Y}_{t+1} = \frac{Y_t + Y_{t-1} + \dots + Y_{t-k+1}}{k}$$

Si las ventas de los últimos tres meses fueron:

1.200, 1.300, 1.400

entonces:

$$\begin{aligned}\hat{Y}_{t+1} &= \frac{1200 + 1300 + 1400}{3} \\ \hat{Y}_{t+1} &= 1300\end{aligned}$$

El pronóstico sería de **1.300 unidades**.

30. Suavización exponencial

Otro procedimiento utilizado es:

$$F_{t+1} = \alpha Y_t + (1 - \alpha)F_t$$

donde:

- F_{t+1} : pronóstico siguiente;
- Y_t : valor real actual;
- F_t : pronóstico actual;
- α : constante de suavización.

Cuanto mayor es α , mayor peso recibe la información reciente.

31. Evaluación de los pronósticos

Un modelo de pronóstico debe evaluarse mediante errores.

Error absoluto medio

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t|$$

Error cuadrático medio

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2$$

Raíz del error cuadrático medio

$$RMSE = \sqrt{MSE}$$

Error porcentual absoluto medio

$$MAPE = \frac{100}{n} \sum \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|$$

En términos generales, valores menores indican mejores pronósticos, aunque la selección de la métrica debe considerar el contexto empresarial.

32. Control estadístico de procesos

El **Statistical Process Control (SPC)** utiliza técnicas estadísticas para monitorear un proceso y distinguir entre variaciones normales y comportamientos que pueden indicar problemas.

Montgomery (2020) considera el SPC una herramienta central para caracterizar, monitorear y mejorar los procesos y lo integra con metodologías más amplias de mejora de calidad como Six Sigma y DMAIC.

Un proceso puede presentar dos clases de variación:

Variación por causas comunes

Es inherente al sistema.

Variación por causas especiales

Surge de acontecimientos específicos:

- maquinaria defectuosa;
- error humano;

- materia prima inadecuada;
- cambio de proveedor;
- fallas tecnológicas.

La finalidad del SPC consiste precisamente en diferenciar ambos tipos.

33. Gráficos de control

Los gráficos de control suelen incorporar:

$LCS =$ Límite de control superior

$LC =$ Línea central

$LCI =$ Límite de control inferior

En condiciones comunes:

$$LCS = \mu + 3\sigma$$

$$LC = \mu$$

$$LCI = \mu - 3\sigma$$

Cuando una observación se encuentra fuera de estos límites, debe investigarse la posible existencia de una causa especial.

34. Gráfico $\bar{X}$

Para controlar medias de muestras:

$$LCS = \bar{\bar{X}} + A_2\bar{R}$$

$$LC = \bar{\bar{X}}$$

$$LCI = \bar{\bar{X}} - A_2\bar{R}$$

Este tipo de gráfico permite verificar si la tendencia central del proceso permanece estable.

35. Gráfico R

El gráfico de rango controla la variabilidad.

$$LCS = D_4\bar{R}$$

$$LC = \bar{R}$$

$$LCI = D_3\bar{R}$$

Los factores D_3 y D_4 dependen del tamaño de las muestras.

La utilización conjunta de gráficos $\bar{X}$ y R permite evaluar:

Centro del proceso + Variabilidad

36. Gráficos para atributos

Cuando se analizan productos defectuosos o número de defectos pueden utilizarse otros gráficos.

Entre ellos:

- gráfico p ;
- gráfico np ;
- gráfico c ;
- gráfico u .

Gráfico p

Controla la proporción de unidades defectuosas.

$$\bar{p} = \frac{\text{Número total defectuosos}}{\text{Número total inspeccionados}}$$

Sus límites pueden calcularse mediante:

$$LCS = \bar{p} + 3 \sqrt{\frac{\bar{p}(1 - \bar{p})}{n}}$$
$$LCI = \bar{p} - 3 \sqrt{\frac{\bar{p}(1 - \bar{p})}{n}}$$

37. Capacidad del proceso

Un proceso puede encontrarse estadísticamente estable pero no necesariamente cumplir las especificaciones del cliente.

Por esta razón se utilizan índices de capacidad.

Índice C_p

$$C_p = \frac{LSE - LIE}{6\sigma}$$

donde:

- LSE: límite superior de especificación;
- LIE: límite inferior de especificación.

El índice compara el rango permitido con la variabilidad natural del proceso.

38. Índice C_{pk}

El índice C_{pk} considera además el centrado del proceso.

$$C_{pk} = \min \left[\frac{LSE - \mu}{3\sigma}, \frac{\mu - LIE}{3\sigma} \right]$$

Un proceso puede tener un buen C_p pero bajo C_{pk} si su promedio está desplazado hacia uno de los límites.

Montgomery plantea precisamente los estudios de capacidad como parte importante de los métodos modernos de control y mejora de procesos.

39. Ejemplo de capacidad

Una fábrica debe producir envases entre:

$$495 \text{ g} \leq X \leq 505 \text{ g}$$

Supóngase:

$$\begin{aligned}\mu &= 500 \\ \sigma &= 1\end{aligned}$$

Entonces:

$$\begin{aligned}C_p &= \frac{505 - 495}{6(1)} \\ C_p &= 1.67\end{aligned}$$

El proceso presenta una capacidad favorable si además permanece adecuadamente centrado y estable.

Si el promedio cambia a:

$$\mu = 503$$

el C_{pk} disminuirá considerablemente porque el proceso se acerca al límite superior.

40. Estadística y gestión de inventarios

El inventario constituye otra importante aplicación de la estadística.

La variabilidad de la demanda influye en las decisiones sobre inventario de seguridad.

Una expresión sencilla es:

$$SS = Z\sigma_L$$

donde:

- SS : stock de seguridad;

- Z : nivel de servicio;
- σ_L : desviación estándar de la demanda durante el tiempo de reposición.

El punto de reorden puede expresarse:

$$ROP = dL + SS$$

donde:

- d : demanda promedio;
- L : tiempo de reposición.

Por tanto, una mejor estimación estadística de la demanda contribuye a disminuir simultáneamente:

Riesgo de ruptura

y

Exceso de inventario

41. Indicadores estadísticos de gestión operacional

Las empresas pueden utilizar KPI para monitorear sistemáticamente los procesos.

Indicador	Fórmula
Productividad	Producción / Recursos
Eficiencia	Resultado real / Resultado esperado
Utilización	Producción real / Capacidad disponible
Tasa de defectos	Defectuosos / Producción $\times 100$
Cumplimiento de entregas	Entregas a tiempo / Total $\times 100$
Rotación de inventario	Costo de ventas / Inventario promedio
Tiempo de ciclo	Tiempo total / Unidades
Tasa de devoluciones	Devoluciones / Ventas $\times 100$

42. Productividad

La productividad puede expresarse mediante:

$$Productividad = \frac{Outputs}{Inputs}$$

Supóngase una empresa que produce:

1.000 unidades

utilizando:

200 horas

Entonces:

$$Productividad = \frac{1000}{200} = 5$$

La productividad es de:

5 unidades/hora

Si posteriormente aumenta a 6 unidades/hora manteniendo estándares de calidad, puede interpretarse como una mejora operacional.

43. Eficiencia y eficacia

Aunque suelen confundirse, representan conceptos diferentes.

Eficacia

Evalúa el grado de cumplimiento del objetivo.

$$Eficacia = \frac{Resultado\ alcanzado}{Resultado\ planificado} \times 100$$

Eficiencia

Relaciona los resultados obtenidos con los recursos utilizados.

Una empresa puede ser eficaz porque cumple una meta de producción, pero ser ineficiente si requiere recursos excesivos para lograrla.

44. Overall Equipment Effectiveness

En organizaciones productivas puede utilizarse el indicador OEE:

$$OEE = Disponibilidad \times Rendimiento \times Calidad$$

Por ejemplo:

$$\begin{aligned} Disponibilidad &= 0.90 \\ Rendimiento &= 0.95 \\ Calidad &= 0.98 \end{aligned}$$

Entonces:

$$OEE = 0.90(0.95)(0.98)$$

$$OEE = 0.8379$$

$$OEE = 83.79\%$$

Este indicador permite integrar tres dimensiones fundamentales del desempeño del equipo.

45. Pareto aplicado a las operaciones

El análisis de Pareto permite identificar cuáles problemas concentran mayor impacto.

Supóngase:

Problema	Frecuencia
Retraso de proveedor	45
Error de producción	25
Fallo de máquina	15
Error administrativo	10
Otros	5

Total:

100

Los dos primeros problemas representan:

$$45 + 25 = 70\%$$

de las incidencias.

Por tanto, concentrar esfuerzos inicialmente en esos factores puede generar mayor impacto.

Esta lógica se relaciona con el principio:

pocos factores vitales frente a muchos factores triviales, aunque no siempre la proporción observada será exactamente 80/20.

46. Six Sigma y estadística

Six Sigma constituye una metodología de mejora que utiliza herramientas estadísticas para reducir defectos y variabilidad.

Su enfoque DMAIC comprende:

D – Define

Definir el problema.

M – Measure

Medir el desempeño actual.

A – Analyze

Identificar las causas.

I – Improve

Implementar mejoras.

C – Control

Mantener los resultados.

Montgomery (2020) integra DMAIC dentro del control estadístico de calidad como un marco sistemático para la resolución y mejora de problemas.

El proceso puede representarse:

Problema → Medición → Análisis → Mejora → Control

47. Estadística aplicada a empresas de servicios

Las técnicas estadísticas no se limitan al sector industrial.

Pueden utilizarse en:

Hospitales

- tiempo de espera;
- número de pacientes;
- ocupación;
- duración de atención.

Universidades

- matrícula;
- deserción;
- rendimiento;
- satisfacción estudiantil.

Bancos

- tiempo de atención;
- mora;
- número de transacciones;
- riesgo crediticio.

Comercio

- ventas;

- demanda;
- inventarios;
- clientes.

Transporte

- tiempo de recorrido;
- puntualidad;
- consumo;
- frecuencia de fallas.

El control estadístico de calidad contemporáneo contempla explícitamente aplicaciones tanto industriales como no manufactureras.

48. Software para análisis estadístico operacional

Actualmente existen múltiples herramientas.

Herramienta	Aplicación
Excel	Estadística básica y análisis empresarial
SPSS	Estadística inferencial
R	Estadística y modelado
Python	Analítica y automatización
Minitab	Calidad y Six Sigma
Power BI	Indicadores y visualización
Orange	Minería de datos y ML
Tableau	Visualización

La selección depende de:

- complejidad;
- volumen de datos;
- conocimientos técnicos;
- costos;
- integración;
- objetivos analíticos.

La obra de Montgomery incluye, por ejemplo, aplicaciones orientadas al uso de software estadístico como Minitab en problemas de control de calidad.

49. De la estadística tradicional a la analítica avanzada

La estadística contemporánea se encuentra cada vez más integrada con:

- minería de datos;
- inteligencia artificial;
- aprendizaje automático;
- optimización;
- visualización;
- Business Intelligence.

Puede establecerse una progresión:

Estadística descriptiva



Inferencia



Modelos explicativos



Modelos predictivos



Machine Learning



Inteligencia Artificial

Sin embargo, los modelos más avanzados continúan dependiendo de conceptos estadísticos fundamentales.

Por ejemplo, para evaluar un algoritmo de aprendizaje automático siguen siendo relevantes elementos como:

- media;
- varianza;
- probabilidad;
- distribución;

- error;
- muestreo;
- validación.

50. Caso aplicado: empresa comercial

Considérese una empresa distribuidora que desea mejorar sus operaciones.

Dispone de la siguiente información mensual:

Variable	Valor
Pedidos	2.500
Entregas a tiempo	2.200
Productos vendidos	12.000
Productos devueltos	300
Inventario promedio	\$40.000
Costo de ventas	\$240.000
Tiempo medio de entrega	3,8 días
Desviación estándar	1,2 días

50.1. Cumplimiento de entregas

$$CE = \frac{2200}{2500} \times 100$$

$$CE = 88\%$$

Por tanto, el 12 % de los pedidos no se entrega dentro del plazo establecido.

51. Tasa de devolución

$$TD = \frac{300}{12000} \times 100$$

$$TD = 2.5\%$$

Esto significa que aproximadamente 2,5 productos de cada 100 vendidos son devueltos.

52. Rotación de inventarios

$$RI = \frac{240000}{40000}$$

$$RI = 6$$

El inventario rota aproximadamente seis veces durante el período considerado, dependiendo de la periodicidad de los datos empleados.

53. Variabilidad de tiempos

La empresa posee:

$$\begin{aligned}\bar{x} &= 3.8 \\ s &= 1.2\end{aligned}$$

Entonces:

$$\begin{aligned}CV &= \frac{1.2}{3.8} \times 100 \\ CV &\approx 31.58\%\end{aligned}$$

Existe una variabilidad relativa considerable en los tiempos de entrega.

Por ello, no basta con reducir el promedio. También debería reducirse la dispersión.

54. Diagnóstico estadístico operacional

A partir de la información anterior puede proponerse:

Problema 1: 12 % de entregas tardías.

Problema 2: 2,5 % de devoluciones.

Problema 3: alta variabilidad del tiempo de entrega.

El análisis puede ampliarse incorporando:

- proveedor;
- ciudad;
- producto;
- transportista;
- día;
- volumen del pedido.

Luego podrían aplicarse:

ANOVA

para comparar tiempos entre transportistas;

Correlación

para relacionar tamaño del pedido y tiempo;

Regresión

para explicar retrasos;

y

Gráficos de control

para monitorear el proceso.

55. Propuesta de ciclo estadístico para la gestión operacional

Un modelo práctico puede estructurarse en nueve etapas:

1. Definir el problema

↓

2. Identificar el indicador

↓

3. Recopilar datos

↓

4. Depurar los datos

↓

5. Describir

↓

6. Analizar

↓

7. Modelar

↓

8. Tomar decisiones

↓

9. Controlar resultados

Este enfoque evita uno de los errores más frecuentes: realizar análisis estadísticos sin vincularlos con una decisión empresarial concreta.

56. Tablero estadístico operacional

Una organización puede implementar un dashboard con indicadores como:

KPI	Resultado	Meta
Productividad	92 %	95 %
Entregas a tiempo	88 %	95 %
Defectos	3,2 %	<2 %
Utilización	81 %	85 %
Devoluciones	2,5 %	<2 %
Tiempo de entrega	3,8 días	3 días

El dashboard permite identificar rápidamente desviaciones.

Pero visualizar los indicadores representa únicamente el primer nivel de análisis.

La secuencia correcta sería:

Indicador → Desviación → Causa → Predicción → Acción

57. Estadística y toma de decisiones operacionales

La estadística puede apoyar decisiones en tres niveles.

Nivel operativo

Decisiones cotidianas:

- asignación de personal;
- programación de máquinas;
- reposición de inventarios.

Nivel táctico

Decisiones de mediano plazo:

- contratación;
- selección de proveedores;
- planificación de capacidad.

Nivel estratégico

Decisiones de largo plazo:

- nueva planta;
- automatización;
- expansión;
- inversión tecnológica.

Por tanto, la estadística no constituye exclusivamente una herramienta técnica. También constituye un instrumento de gestión.

58. Limitaciones del análisis estadístico

Los resultados estadísticos deben interpretarse cuidadosamente.

Algunas limitaciones son:

- datos incompletos;
- sesgo de selección;
- errores de medición;
- muestras pequeñas;
- supuestos incumplidos;
- variables omitidas;
- correlaciones espurias;
- cambios en el entorno.

Un resultado estadísticamente significativo no necesariamente representa una mejora empresarial importante.

Por ejemplo:

$$p < 0.05$$

puede mostrar que una diferencia existe, pero la empresa también debe evaluar:

Impacto económico
Costo de implementación
Viabilidad
Riesgo

59. Significación estadística y significación empresarial

Es importante distinguir ambos conceptos.

Significación estadística

Determina si la evidencia observada resulta difícil de explicar únicamente por azar bajo determinado modelo.

Significación empresarial

Evalúa si el efecto es suficientemente importante para justificar una decisión.

Por ejemplo, una nueva tecnología podría reducir estadísticamente el tiempo de producción desde:

10.00

a:

9.95 minutos

La diferencia podría llegar a ser estadísticamente significativa con una muestra muy grande.

Sin embargo, si implementar la tecnología cuesta USD 1 millón, la mejora podría no ser empresarialmente relevante.

Por tanto:

$$\text{Buena decisión} = \text{Evidencia estadística} + \text{Impacto empresarial}$$

60. Nuevas tendencias de la estadística operacional

La gestión operacional está evolucionando hacia modelos en tiempo real.

Actualmente, la estadística puede integrarse con:

- sensores IoT;
- sistemas ERP;
- inteligencia artificial;
- mantenimiento predictivo;
- gemelos digitales;
- analítica de procesos;
- aprendizaje automático;
- plataformas cloud.

La estadística deja entonces de utilizarse únicamente para analizar lo ocurrido y comienza a integrarse directamente dentro de los procesos.

Por ejemplo:

$$\text{Sensor} \rightarrow \text{Dato} \rightarrow \text{Modelo} \rightarrow \text{Alerta} \rightarrow \text{Intervención}$$

Esta integración permite detectar anomalías antes de que se conviertan en fallas importantes.

61. Mantenimiento predictivo

Un área especialmente relevante consiste en utilizar datos históricos de equipos para estimar probabilidades de falla.

Las variables pueden incluir:

Temperatura

Vibración

Presión

Horas de funcionamiento

Historial de fallas

Un modelo podría estimar:

$$P(F, a, l, la = 1 \mid X_1 X_2 \dots X_k)$$

La organización puede entonces intervenir el equipo antes de producirse la falla.

Esto transforma:

Mantenimiento correctivo → Preventivo → Predictivo

62. Competencias estadísticas del gestor moderno

La transformación digital implica que los responsables empresariales no necesariamente deben convertirse en estadísticos profesionales, pero sí desarrollar alfabetización estadística.

Entre las competencias fundamentales se encuentran:

- interpretar promedios;
- comprender variabilidad;
- analizar gráficos;
- distinguir correlación y causalidad;
- comprender intervalos;
- interpretar valores p ;
- evaluar pronósticos;
- identificar valores atípicos;
- interpretar modelos;
- detectar resultados engañosos.

Estas competencias son cada vez más importantes porque muchas decisiones gerenciales se apoyan en dashboards y algoritmos.

63. Integración con la analítica empresarial

Este capítulo conecta directamente con el anterior.

En términos generales:

Analítica empresarial

utiliza:

Estadística + Tecnología + Datos + Modelos + Conocimiento del negocio

La estadística proporciona una parte esencial de los fundamentos metodológicos.

Puede establecerse la siguiente relación:

Nivel analítico	Herramientas estadísticas
Descriptivo	Media, porcentajes, gráficos
Diagnóstico	Correlación, ANOVA
Predictivo	Regresión, series temporales
Prescriptivo	Probabilidad, simulación, optimización

Por tanto, el dominio de la estadística operacional constituye una base necesaria para avanzar hacia minería de datos, aprendizaje automático y modelos predictivos.

64. Conclusiones

La estadística representa una herramienta fundamental para la gestión operacional porque permite convertir datos cotidianos de los procesos empresariales en evidencia para la toma de decisiones. Su aplicación abarca desde el análisis descriptivo de indicadores hasta el control estadístico, la inferencia, los pronósticos y la modelización de relaciones entre variables.

Uno de los principales aportes de la estadística consiste en reconocer que la variabilidad forma parte de todos los procesos. Por ello, administrar operaciones no significa únicamente incrementar los resultados promedio, sino también lograr procesos más consistentes, predecibles y controlados.

La utilización de herramientas como media, desviación estándar, coeficiente de variación, intervalos de confianza, pruebas de hipótesis, ANOVA, correlación, regresión, series temporales y gráficos de control permite analizar los procesos desde diferentes perspectivas.

Particular importancia adquiere el control estadístico de procesos, que permite diferenciar la variabilidad inherente de aquella generada por causas especiales. Esta distinción facilita identificar problemas y diseñar intervenciones orientadas a la mejora continua.

Asimismo, los métodos estadísticos proporcionan los fundamentos para aplicaciones contemporáneas relacionadas con analítica empresarial, minería de datos, aprendizaje automático y mantenimiento predictivo.

En consecuencia, la estadística aplicada a la gestión operacional debe entenderse como un componente integral del proceso gerencial:

Medir → Analizar → Comprender → Predecir → Decidir → Mejorar

Una organización que desarrolla estas capacidades puede reducir incertidumbre, controlar sus procesos y tomar decisiones sustentadas en evidencia en lugar de depender exclusivamente de la intuición.

Referencias

Black, K. (2024). *Business statistics: For contemporary decision making* (11th ed.). Wiley.

Bruce, P., Bruce, A., & Gedeck, P. (2020). *Practical statistics for data scientists: 50+ essential concepts using R and Python* (2nd ed.). O'Reilly Media.

Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts.

James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). *An introduction to statistical learning: With applications in Python*. Springer. <https://doi.org/10.1007/978-3-031-38747-0>

Montgomery, D. C. (2020). *Introduction to statistical quality control* (8th ed.). Wiley. La edición aborda control estadístico de procesos, caracterización y optimización de procesos, muestreo de aceptación y estrategias Six Sigma.

Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2015). *Introduction to time series analysis and forecasting* (2nd ed.). Wiley.

Provost, F., & Fawcett, T. (2013). *Data science for business: What you need to know about data mining and data-analytic thinking*. O'Reilly Media.

Shmueli, G., Bruce, P. C., Gedeck, P., & Patel, N. R. (2023). *Data mining for business analytics: Concepts, techniques, and applications in Python*. Wiley.

CAPÍTULO 3

Sistemas de información y toma de decisiones

Mario Alberto Touma Faytong

mtoumaf@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0000-0002-4855-119X>

Alberto Eduardo Colcha Seilema

acolcha@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0000-0001-6611-2652>

1. Introducción

La transformación digital ha modificado profundamente la manera en que las organizaciones recopilan, procesan, almacenan y utilizan información. En el entorno empresarial contemporáneo, los sistemas de información dejaron de constituir únicamente herramientas destinadas a automatizar procesos administrativos para convertirse en componentes estratégicos capaces de apoyar la planificación, el control, la innovación y la toma de decisiones.

Los sistemas de información integran recursos tecnológicos, personas, procedimientos, bases de datos y mecanismos de comunicación con el propósito de transformar datos en información útil. Laudon, Laudon y Traver (2025) destacan que los sistemas de información empresariales mantienen una relación directa con el desempeño organizacional y actualmente incorporan tecnologías como inteligencia artificial, computación en la nube, Internet de las cosas, big data y analítica empresarial.

La importancia de estos sistemas aumenta conforme las organizaciones generan mayores volúmenes de datos. Ventas, compras, inventarios, clientes, proveedores, operaciones financieras y actividades de marketing producen continuamente registros que pueden utilizarse para identificar tendencias, evaluar resultados y anticipar escenarios.

La Organización para la Cooperación y el Desarrollo Económicos señala que las tecnologías digitales y los datos han modificado los mercados y las formas en que operan las empresas. El uso de computación en la nube, IoT, inteligencia artificial y herramientas basadas en datos continúa expandiéndose, aunque con diferencias importantes entre empresas y sectores (OECD, 2024a).

Por ello, la relación entre sistemas de información y toma de decisiones puede representarse mediante:

Datos → Procesamiento → Información → Conocimiento → Decisión → Acción

El presente capítulo analiza los fundamentos de los sistemas de información empresariales, los principales tipos existentes, su integración mediante ERP, CRM y SCM, el papel de las bases de datos y los sistemas de inteligencia de negocios, así como la incorporación de inteligencia artificial y analítica avanzada en los procesos de decisión.

2. Concepto de sistema de información

Un sistema de información puede entenderse como un conjunto organizado de componentes interrelacionados que recopilan, procesan, almacenan y distribuyen información para apoyar las actividades y decisiones de una organización.

Puede expresarse conceptualmente como:

$$SI = f(Personas, Datos, Procesos, Tecnología)$$

Por consiguiente, un sistema de información no corresponde únicamente al software utilizado por una empresa.

Para que exista un sistema funcional deben integrarse al menos cinco componentes:

Componente	Función
Personas	Utilizan y administran el sistema
Datos	Constituyen la materia prima
Hardware	Permite procesamiento y almacenamiento
Software	Ejecuta las funciones
Procesos	Determinan cómo se utiliza la información

A estos componentes debe añadirse actualmente la infraestructura de comunicaciones que permite la interconexión entre usuarios, sistemas internos, proveedores, clientes y plataformas externas.

3. Diferencia entre datos, información y conocimiento

Estos conceptos suelen utilizarse indistintamente, aunque representan niveles diferentes.

Datos

Son registros elementales sin interpretación suficiente.

Ejemplo:

1200, 1350, 1420, 1280

Por sí mismos ofrecen un significado limitado.

Información

Surge cuando los datos son organizados y contextualizados.

Por ejemplo:

Mes	Ventas
Enero	1.200
Febrero	1.350
Marzo	1.420

Abril	1.280
--------------	-------

Ahora puede observarse la evolución mensual.

Conocimiento

Se produce al interpretar la información.

Por ejemplo:

Las ventas crecieron durante los tres primeros meses, pero disminuyeron en abril.

Decisión

El conocimiento se convierte en una alternativa de acción.

Por ejemplo:

Analizar las causas de la reducción y reforzar las campañas comerciales.

El proceso puede resumirse:

Dato → Información → Conocimiento → Decisión

Una organización orientada por datos debe conseguir que esta secuencia ocurra de manera sistemática.

4. Características de la información de calidad

La efectividad de una decisión depende, en gran medida, de la calidad de la información disponible.

Entre las características más importantes se encuentran:

- exactitud;
- relevancia;
- oportunidad;
- integridad;
- consistencia;
- accesibilidad;
- comprensibilidad;
- seguridad.

Puede representarse:

Calidad de información = f(E, R, O, I, C, A, S)

Una información puede ser correcta, pero perder utilidad si llega demasiado tarde.

Por ejemplo, conocer el nivel de inventario mensual puede ser insuficiente en una empresa con ventas diarias elevadas. En ese contexto se requerirá información prácticamente en tiempo real.

5. Funciones básicas de un sistema de información

Los sistemas de información cumplen cuatro funciones fundamentales.

5.1. Entrada

Consiste en recopilar datos.

Ejemplos:

- registro de ventas;
- datos de clientes;
- órdenes de compra;
- inventarios;
- pagos;
- asistencia de empleados.

5.2. Procesamiento

Los datos se transforman.

Por ejemplo:

Ventas diarias → Ventas mensuales

5.3. Salida

El sistema genera resultados.

Ejemplos:

- informes;
- gráficos;
- indicadores;
- alertas;
- dashboards.

5.4. Retroalimentación

Los resultados obtenidos pueden utilizarse para corregir o modificar procesos.

El flujo general puede representarse como:

Entrada → Procesamiento → Salida

con:

Retroalimentación

como mecanismo de control.

6. Sistemas de información según el nivel organizacional

Las organizaciones poseen diferentes niveles de decisión.

Por ello, los sistemas de información pueden clasificarse según el tipo de usuario y el nivel administrativo al cual apoyan.

Nivel	Sistema predominante
Operativo	TPS
Administrativo	MIS
Táctico	DSS
Estratégico	ESS/EIS

7. Sistemas de procesamiento de transacciones

Los **Transaction Processing Systems (TPS)** registran operaciones rutinarias y repetitivas.

Ejemplos:

- ventas;
- facturación;
- nómina;
- depósitos;
- matrículas;
- reservas;
- compras.

Su finalidad principal es garantizar que las transacciones se registren con:


- precisión;
- velocidad;
- consistencia;
- seguridad.

Por ejemplo, cuando un supermercado realiza una venta, el TPS puede registrar simultáneamente:

Venta



Actualización del inventario



Los TPS constituyen una fuente importante para sistemas analíticos posteriores.

8. Sistemas de información gerencial

Los **Management Information Systems (MIS)** utilizan información procedente principalmente de las operaciones para elaborar reportes orientados a los administradores.

Por ejemplo:

- ventas mensuales;
- presupuesto ejecutado;
- inventario disponible;
- productividad;
- cartera vencida;
- ausentismo.

Un MIS podría mostrar:

Indicador	Resultado
Ventas mensuales	\$380.000
Cumplimiento meta	92 %
Inventario	\$85.000
Morosidad	6,2 %
Rentabilidad	12,5 %

Su función principal consiste en facilitar el seguimiento y control administrativo.

9. Sistemas de apoyo a las decisiones

Los **Decision Support Systems (DSS)** permiten analizar alternativas cuando el problema no se encuentra completamente estructurado.

Sharda, Delen y Turban (2024) vinculan los sistemas contemporáneos de apoyo a decisiones con inteligencia de negocios, analítica, ciencia de datos e inteligencia artificial, destacando el creciente papel de estas tecnologías en la gestión empresarial.

Un DSS puede integrar:

Datos + Modelos + Escenarios

Por ejemplo, una empresa puede preguntarse:

¿Qué ocurriría si incrementamos el precio un 5 %?

El sistema podría analizar diferentes escenarios:

Escenario	Precio	Demanda estimada	Utilidad
A	Actual	10.000	\$45.000
B	+5 %	9.400	\$49.000
C	+10 %	8.300	\$46.000

La administración podría seleccionar el escenario B al proporcionar la mayor utilidad esperada.

10. Sistemas de información ejecutiva

Los **Executive Information Systems (EIS)** o sistemas de soporte ejecutivo presentan información altamente resumida para la alta dirección.

Generalmente utilizan:

- KPI;
- tendencias;
- cuadros de mando;
- comparaciones;
- alertas;
- escenarios.

Por ejemplo:

Dashboard ejecutivo

Ventas: 92% de la meta

Rentabilidad: 13.5%

Liquidez: 1.8

Participación de mercado: 21%

Satisfacción del cliente: 89%

El objetivo no consiste en presentar grandes cantidades de datos, sino en identificar rápidamente las variables estratégicas que requieren atención.

11. Niveles de decisión empresarial

Las decisiones empresariales pueden clasificarse en tres niveles.

Decisiones operativas

Se relacionan con actividades cotidianas.

Ejemplos:

- aceptar un pedido;
- asignar personal;
- emitir una factura;
- reponer inventario.

Decisiones tácticas

Corresponden al mediano plazo.

Ejemplos:

- establecer presupuestos;
- seleccionar proveedores;
- diseñar campañas;
- contratar personal.

Decisiones estratégicas

Se relacionan con el largo plazo.

Ejemplos:

- ingresar a nuevos mercados;
- adquirir otra empresa;
- crear una nueva línea de productos;
- automatizar procesos.

En términos generales:

Operativo → Corto plazo

Táctico → Mediano plazo

Estratégico → Largo plazo

Los diferentes sistemas de información deben proporcionar información apropiada para cada nivel.

12. Decisiones estructuradas, semiestructuradas y no estructuradas

Otro criterio consiste en analizar el nivel de estructuración.

Decisiones estructuradas

Siguen reglas claramente establecidas.

Ejemplo:

Si:

$$\text{Inventario} < \text{Stock mínimo}$$

entonces:

Generar orden de compra

Decisiones semiestructuradas

Combinan reglas con juicio humano.

Ejemplo:

Seleccionar un proveedor considerando precio, calidad, tiempo de entrega y experiencia.

Decisiones no estructuradas

Presentan altos niveles de incertidumbre.

Ejemplo:

Determinar si una empresa debe ingresar a otro país.

Los DSS y las herramientas de analítica resultan especialmente relevantes para las decisiones semiestructuradas y no estructuradas.

13. Sistemas ERP

Los sistemas **Enterprise Resource Planning (ERP)** integran diferentes funciones empresariales dentro de una plataforma común.

Gronwald (2026) destaca la integración de ERP con SCM, CRM, inteligencia de negocios, big data y tecnologías de inteligencia artificial como parte de los actuales sistemas empresariales.

Un ERP puede integrar:

Finanzas
Compras
Inventarios
Producción
Ventas
Talento humano
Contabilidad

En lugar de mantener bases independientes, los departamentos comparten información.

14. Ejemplo de integración ERP

Supóngase que un cliente realiza una compra.

El ERP puede ejecutar:

1. Registrar venta

↓

2. Reducir inventario

↓

3. Generar factura

↓

4. Registrar cuenta por cobrar

↓

5. Actualizar contabilidad

↓

6. Informar disponibilidad

La principal ventaja es reducir duplicación y mejorar consistencia.

Sin integración podrían coexistir diferentes registros:

$$\text{Inventario}_{\text{Ventas}} \neq \text{Inventario}_{\text{Bodega}}$$

Con ERP:

$$\text{Base integrada} \rightarrow \text{Información consistente}$$

15. Ventajas del ERP

Entre los principales beneficios se encuentran:

- integración de procesos;
- reducción de duplicidad;
- automatización;
- trazabilidad;
- disponibilidad de información;
- estandarización;
- mejor control;

- generación de indicadores.

Sin embargo, también existen desafíos:

- costos;
- implementación compleja;
- capacitación;
- resistencia al cambio;
- dependencia tecnológica;
- adaptación de procesos.

Por ello, la implementación de ERP debe entenderse como un proyecto organizacional, no simplemente tecnológico.

16. Customer Relationship Management

Los sistemas **CRM** administran información relacionada con clientes.

Sus principales funciones incluyen:

- historial de compras;
- contactos;
- oportunidades comerciales;
- campañas;
- servicio al cliente;
- reclamaciones;
- segmentación.

Un CRM puede responder preguntas como:

¿Quiénes son nuestros clientes más importantes?

¿Qué clientes están reduciendo sus compras?

¿Qué productos adquiere cada segmento?

¿Qué clientes tienen mayor probabilidad de abandonar la empresa?

El CRM convierte la relación con el cliente en una fuente estructurada de información.

17. Valor del cliente

Uno de los indicadores utilizados en CRM es el **Customer Lifetime Value (CLV)**.

Una representación simplificada es:

$$CLV = \sum_{t=1}^T \frac{Margen_t \times Retención_t}{(1+r)^t}$$

donde:

- $Margen_t$: contribución del cliente;
- $Retención_t$: probabilidad de permanencia;
- r : tasa de descuento;
- T : horizonte temporal.

El objetivo consiste en comprender que no todos los clientes generan el mismo valor.

Esto permite orientar estrategias hacia:

Adquisición
Retención
Fidelización

18. Supply Chain Management

Los sistemas **SCM** apoyan la administración de la cadena de suministro.

Integran información relacionada con:

- proveedores;
- compras;
- producción;
- almacenamiento;
- distribución;
- transporte;
- clientes.

Su propósito es coordinar el flujo de:

Materiales
Información
Dinero

a través de la cadena.

19. Flujo de información en SCM

Una cadena simplificada podría ser:

Proveedor → Fabricante → Distribuidor → Minorista → Cliente

Pero simultáneamente circula información:

Demanda ← Pedidos ← Inventarios

Una adecuada gestión de información permite disminuir:

- exceso de inventarios;
- rupturas de stock;
- retrasos;
- costos logísticos.

Los sistemas SCM modernos se encuentran cada vez más conectados con analítica e inteligencia artificial para estimar demanda y optimizar operaciones (Gronwald, 2026).

20. Integración ERP–CRM–SCM

Una de las principales tendencias es integrar estos sistemas.

Puede representarse como:

CRM → Demanda del cliente

ERP → Recursos internos

SCM → Cadena de suministro

La integración genera:

Cliente ↔ Empresa ↔ Proveedor

Por ejemplo, si el CRM detecta un incremento de demanda, el ERP puede determinar capacidad disponible y el SCM coordinar el abastecimiento.

21. Bases de datos

Los sistemas de información dependen de bases de datos para almacenar información de manera organizada.

Una base de datos empresarial puede contener tablas como:

Clientes

ID Nombre Ciudad

Productos

ID Producto Precio

Ventas

ID Cliente Producto Cantidad

La relación entre tablas permite construir consultas complejas.

Por ejemplo:

¿Cuáles son los cinco clientes de Babahoyo que más compraron durante agosto?

Una consulta puede combinar:

Clientes + Ventas + Productos

para responderla.

22. Data warehouse

Los sistemas transaccionales están diseñados principalmente para registrar operaciones.

El **data warehouse**, en cambio, se orienta hacia el análisis.

Puede integrar información proveniente de:

- ERP;
- CRM;
- SCM;
- archivos;
- páginas web;
- sistemas externos.

El proceso tradicional puede representarse mediante:

Fuentes → ETL → Data Warehouse → BI

ETL significa:

Extract → Transform → Load

o:

Extraer → Transformar → Cargar

23. Data marts

Un **data mart** corresponde a una parte especializada del almacén de datos.

Por ejemplo:

Data Warehouse

puede dividirse en:

Data Mart_{Ventas}
Data Mart_{Finanzas}
Data Mart_{Marketing}
Data Mart_{RRHH}


Esto facilita que cada área acceda a información relevante para sus necesidades.

24. Business Intelligence

La inteligencia de negocios integra tecnologías y procesos destinados a transformar datos en información para apoyar decisiones.

Sharda et al. (2024) plantean una visión contemporánea en la cual BI, analítica, ciencia de datos e inteligencia artificial constituyen herramientas complementarias para los responsables empresariales.

La arquitectura básica puede representarse:



25. Dashboards

Un dashboard permite visualizar indicadores de manera integrada.

Por ejemplo:

Dashboard comercial

KPI	Actual	Meta
Ventas	\$480.000	\$500.000
Clientes nuevos	320	350
Conversión	7,8 %	8,5 %
Ticket promedio	\$74	\$70
Retención	91 %	90 %

El dashboard no debe limitarse a mostrar números.

Debe facilitar la identificación de:

Situación → Desviación → Causa → Acción

26. KPI y sistemas de información

Los sistemas empresariales permiten automatizar el cálculo de indicadores.

Un KPI puede expresarse como:

$$KPI = \frac{\text{Resultado}}{\text{Referencia}}$$

Por ejemplo:

Cumplimiento de ventas

$$CV = \frac{\text{Ventas reales}}{\text{Ventas presupuestadas}} \times 100$$

Si:

$$\text{Ventas} = 480000$$

y:

$$\text{Meta} = 500000$$

se obtiene:

$$CV = 96\%$$

Un sistema BI puede actualizar automáticamente este indicador.

27. Sistemas de información y analítica empresarial

La evolución de los sistemas de información conduce hacia plataformas analíticas.

El sistema tradicional responde:

¿Cuánto vendimos?

La analítica descriptiva responde:

¿Cómo se distribuyeron las ventas?

La analítica diagnóstica responde:

¿Por qué disminuyeron?

La analítica predictiva responde:

¿Cuánto venderemos?

La analítica prescriptiva responde:

¿Qué deberíamos hacer?

La evolución puede expresarse:

Registro → Información → Análisis → Predicción → Optimización

28. Inteligencia artificial en los sistemas de información

La incorporación de IA representa uno de los cambios más importantes en los sistemas empresariales.


La edición actual de *Management Information Systems: Managing the Digital Firm* incorpora expresamente inteligencia artificial junto con sostenibilidad, computación en la nube, IoT, big data y BI como tecnologías contemporáneas de los sistemas organizacionales (Laudon et al., 2025).

La IA puede utilizarse para:

- detectar fraude;
- recomendar productos;
- clasificar clientes;
- analizar documentos;
- predecir ventas;
- automatizar consultas;
- generar reportes;
- analizar sentimientos;

- apoyar decisiones.

Por ejemplo:



29. Inteligencia artificial generativa

La IA generativa incorpora capacidades adicionales.

Puede utilizarse para:

- consultar bases mediante lenguaje natural;
- generar informes ejecutivos;
- resumir documentos;
- responder consultas;
- generar escenarios;
- apoyar análisis.

Un gerente podría preguntar:

“¿Cuáles fueron las principales causas de la disminución de ventas del último trimestre?”

El sistema podría integrar:

$ERP + CRM + BI + IA$

para elaborar una respuesta.

Sharda et al. (2024) incorporan en la quinta edición de su obra contenidos específicos sobre IA contemporánea y tecnologías generativas como ChatGPT dentro del campo de BI y analítica.

30. Internet de las cosas

El **Internet of Things (IoT)** permite conectar objetos físicos con sistemas digitales.

Por ejemplo:

Sensor → Internet → Base de datos → Analítica

Puede utilizarse para:

- monitorear maquinaria;
- controlar temperatura;
- rastrear vehículos;
- medir consumo energético;
- controlar inventarios.

La OECD (2024a) señala que tecnologías como cloud e IoT han mostrado una importante difusión empresarial, mientras las tecnologías más dependientes de datos, como big data e IA, mantienen tasas de adopción comparativamente menores.

31. Computación en la nube

El **cloud computing** permite utilizar recursos tecnológicos a través de Internet.

Entre sus ventajas se encuentran:

- escalabilidad;
- flexibilidad;
- reducción de infraestructura local;
- acceso remoto;
- integración;
- almacenamiento.

Los modelos principales son:

IaaS

Infrastructure as a Service.

PaaS

Platform as a Service.

SaaS

Software as a Service.

Muchos ERP, CRM y plataformas de BI actualmente funcionan bajo SaaS.

32. Sistemas de información y transformación digital

La transformación digital implica algo más profundo que digitalizar documentos.

Puede expresarse como:

$$\textit{Transformación digital} = \textit{Tecnología} + \textit{Procesos} + \textit{Personas} + \textit{Cultura}$$

Una empresa puede disponer de un ERP moderno pero mantener procesos ineficientes.

Por ello:

$$\textit{Tecnología} \neq \textit{Transformación}$$

La transformación ocurre cuando las herramientas digitales modifican la manera en que la organización:

- crea valor;
- interactúa con clientes;
- organiza procesos;
- toma decisiones.

La OECD encontró en una encuesta de pequeñas y medianas empresas digitalizadas que aproximadamente el 72 % de los participantes utilizaba datos para apoyar decisiones, aunque existían diferencias según el nivel de madurez digital (OECD, 2024b).

33. Toma de decisiones basada en datos

Una organización orientada por datos utiliza evidencia de manera sistemática.

Podemos representar:

$$\textit{Decision Quality} = f(D, a, t, a \textit{QualityAnalysisExperienceContext})$$

Por ello, utilizar datos no significa eliminar el juicio administrativo.

La decisión puede combinar:

$$\textit{Evidencia cuantitativa} + \textit{Experiencia} + \textit{Contexto} + \textit{Criterio gerencial}$$

La analítica permite reducir incertidumbre, pero no siempre puede eliminarla completamente.

34. Modelo racional de toma de decisiones

Un proceso estructurado puede seguir estas etapas:

1. Identificar problema

↓

2. Recopilar información



3. Definir alternativas



4. Evaluar alternativas



5. Seleccionar



6. Implementar



7. Evaluar resultados

Los sistemas de información pueden intervenir prácticamente en todas las etapas.

35. Matriz de decisión

Cuando existen múltiples criterios puede emplearse una matriz ponderada.

Supóngase que una empresa debe seleccionar un proveedor.

Criterio	Peso	A	B	C
Precio	0,30	9	7	8
Calidad	0,30	8	9	7
Entrega	0,25	7	8	9
Servicio	0,15	8	8	7

Para el proveedor A:

$$P_A = (0.30)(9) + (0.30)(8) + (0.25)(7) + (0.15)(8)$$
$$P_A = 8.05$$

El mismo procedimiento se aplica a los demás proveedores.

Este análisis puede automatizarse dentro de un DSS.

36. Analítica de escenarios

Los sistemas de apoyo a decisiones también pueden analizar escenarios.

Supóngase:

$$Ventas = 100000$$

La empresa considera tres escenarios.

Escenario	Crecimiento
Pesimista	-10 %
Base	+5 %
Optimista	+15 %

Resultados:

Pesimista = 90000
Base = 105000
Optimista = 115000

La administración puede calcular costos, inventarios y recursos requeridos bajo cada escenario.

37. Sistemas de información en marketing

En marketing pueden utilizarse para:

- segmentación;
- gestión de campañas;
- análisis del cliente;
- recomendación;
- comportamiento digital.

Por ejemplo:

CRM + Web + Compras



Perfil del cliente



Segmentación



Campaña personalizada

Los sistemas de información permiten avanzar desde marketing masivo hacia acciones personalizadas.

38. Sistemas de información financiera

En finanzas pueden utilizarse para:

- presupuestos;
- flujo de caja;
- evaluación crediticia;
- análisis de riesgos;
- control de gastos;
- rentabilidad.

Ejemplo:

$$Liquidez = \frac{Activo\ corriente}{Pasivo\ corriente}$$

El indicador puede actualizarse automáticamente cuando el ERP registra nuevas transacciones.

39. Sistemas de información en operaciones

En operaciones pueden apoyar:

- planificación de producción;
- inventarios;
- control de calidad;
- mantenimiento;
- logística;
- productividad.

Por ejemplo:

$$ERP + IoT + Analítica$$

puede detectar que la vibración de una máquina se encuentra fuera del comportamiento esperado y emitir una alerta de mantenimiento.

40. Sistemas de información en talento humano

Las plataformas de recursos humanos pueden manejar:

- nómina;
- asistencia;
- evaluación;

- capacitación;
- reclutamiento;
- desempeño.

La integración con analítica puede permitir estimar:

$$P(Rotación = 1 | X)$$

a partir de variables como:

- antigüedad;
- salario;
- satisfacción;
- carga laboral;
- ausentismo.

Estas predicciones deben utilizarse responsablemente para evitar decisiones discriminatorias.

41. Seguridad de la información

La dependencia tecnológica aumenta la exposición a riesgos.

Entre ellos:

- acceso no autorizado;
- pérdida de información;
- ransomware;
- fraude;
- robo de credenciales;
- filtraciones;
- interrupciones.

La seguridad debe proteger tres propiedades fundamentales:

Confidencialidad
Integridad
Disponibilidad

conocidas como triada CIA.

42. Ciberseguridad y gestión empresarial

El **NIST Cybersecurity Framework 2.0**, publicado en febrero de 2024, amplió su orientación para que pueda ser utilizado por organizaciones de cualquier tamaño y sector e incorporó mayor énfasis en la gobernanza del riesgo de ciberseguridad (Pascoe et al., 2024).

El marco organiza sus principales funciones alrededor de:

Govern
Identify
Protect
Detect
Respond
Recover

Esto significa que la seguridad debe formar parte de la gestión empresarial y no limitarse al departamento tecnológico.

43. Gobernanza de sistemas de información

La gobernanza establece cómo una organización dirige y controla sus recursos tecnológicos.

Debe definir:

- responsabilidades;
- políticas;
- estándares;
- inversiones;
- seguridad;
- administración de datos.

Puede expresarse:

$$\text{Gobernanza TI} = \text{Alineación} + \text{Control} + \text{Responsabilidad} + \text{Riesgo}$$

El CSF 2.0 enfatiza precisamente que la ciberseguridad debe analizarse junto con otros riesgos empresariales, incluyendo los financieros y reputacionales.

44. Gobierno de datos

El gobierno de datos comprende políticas para administrar:

- propiedad;
- calidad;
- accesos;
- seguridad;

- privacidad;
- almacenamiento;
- uso.

Por ejemplo, una organización debería responder:

¿Quién es responsable de los datos del cliente?

¿Quién puede modificarlos?

¿Durante cuánto tiempo se conservan?

¿Quién puede utilizarlos en modelos analíticos?

Sin gobierno adecuado:

Más datos

no necesariamente generan:

Mejores decisiones

45. Calidad de datos

Los errores en datos pueden propagarse hacia los sistemas analíticos.

Considérese:

*Datos incorrectos → Información incorrecta → Modelo incorrecto
→ Decisión incorrecta*

Por ello se utiliza frecuentemente el principio:

Garbage In, Garbage Out (GIGO).

Los sistemas deben controlar:

- registros duplicados;
- datos incompletos;
- inconsistencias;
- errores de formato;
- valores imposibles.

46. Ética y privacidad

El uso creciente de información empresarial plantea desafíos relacionados con:

- privacidad;

- consentimiento;
- vigilancia;
- sesgos;
- discriminación;
- transparencia.

Un sistema técnicamente eficiente podría ser éticamente cuestionable.

Por ejemplo, un algoritmo de contratación podría aprender sesgos existentes en datos históricos.

Por tanto:

$$\textit{Calidad de decisión} \neq \textit{Sólo precisión}$$

Debe incorporarse:

$$\textit{Precisión} + \textit{Equidad} + \textit{Transparencia} + \textit{Responsabilidad}$$

47. Caso aplicado: empresa comercial

Considérese una empresa que posee cinco sucursales y aproximadamente 20.000 clientes.

Actualmente utiliza:

- Excel para inventarios;
- software contable independiente;
- registros manuales de clientes;
- pedidos por WhatsApp;
- reportes mensuales.

La administración enfrenta problemas de:

- datos duplicados;
- diferencias de inventarios;
- demora en reportes;
- escasa segmentación;
- dificultad para pronosticar ventas.

48. Diagnóstico del sistema actual

El flujo existente puede representarse:

$$\begin{aligned} \textit{Ventas} &\rightarrow \textit{Excel} \\ \textit{Contabilidad} &\rightarrow \textit{Sistema independiente} \end{aligned}$$

Clientes → WhatsApp
Inventario → Archivo separado


La información se encuentra fragmentada.

Esto produce:

Duplicidad + Errores + Retrasos + Falta de integración

49. Propuesta de arquitectura integrada

Puede diseñarse la siguiente estructura:



El CRM gestiona clientes.

El ERP administra recursos internos.

El SCM conecta proveedores.

El data warehouse consolida datos.

BI genera indicadores.

Los modelos predictivos anticipan comportamientos.

50. Dashboard propuesto

La gerencia podría disponer de:

Indicador	Resultado
Ventas	\$820.000
Crecimiento	8,4 %
Margen	16,3 %
Clientes activos	14.250
Rotación de inventario	7,1
Conversión	6,8 %
Entrega puntual	91 %
Devoluciones	2,1 %

Además, cada indicador podría visualizarse:

- por sucursal;
- por producto;
- por vendedor;
- por cliente;
- por período.

51. Incorporación de modelos predictivos

El sistema también podría estimar:

Predicción de ventas

$$Ventas_{t+1} = f(Ventas, precio, promociones, estacionalidad)$$

Predicción de abandono

$$P(Churn = 1) = f(Frecuencia, Recencia, Quejas, Compras)$$

Predicción de demanda

$$Demanda = f(Histórico, Precio, Temporada, Promoción)$$

Con esto, la empresa transitaría de:

Sistema de registro

hacia:

Sistema inteligente de decisión

52. Ejemplo de decisión apoyada por datos

Supóngase que el sistema identifica:

$$P(\text{Abandono}) = 0.82$$

para un cliente de alto valor.

El CRM puede generar una alerta:

Cliente con riesgo elevado.

El sistema podría recomendar:

- oferta personalizada;
- contacto del vendedor;
- descuento;
- programa de fidelización.

Luego se evalúa:

$$\text{Acción} \rightarrow \text{Respuesta} \rightarrow \text{Resultado}$$

Esta retroalimentación vuelve al sistema y mejora decisiones futuras.

53. Madurez de sistemas de información

Las empresas pueden ubicarse en diferentes niveles.

Nivel	Característica
1	Procesos manuales
2	Digitalización básica
3	Sistemas integrados
4	BI y analítica
5	Modelos predictivos
6	Decisiones inteligentes

Puede representarse:

$$\text{Manual} \rightarrow \text{Digital} \rightarrow \text{Integrado} \rightarrow \text{Analítico} \rightarrow \text{Predictivo} \rightarrow \text{Inteligente}$$

Este proceso no depende solamente de la tecnología, sino también de competencias y cultura organizacional.

54. Factores críticos de éxito

La implementación de sistemas de información requiere considerar:

- liderazgo;
- participación de usuarios;
- capacitación;
- calidad de datos;
- infraestructura;
- seguridad;
- procesos;
- cultura;
- alineación estratégica.

Una organización puede invertir importantes recursos tecnológicos y obtener bajos resultados si sus empleados no utilizan los sistemas adecuadamente.

Podemos expresar:

$$\text{Éxito SI} = \text{Tecnología} \times \text{Personas} \times \text{Procesos}$$

La forma multiplicativa permite representar que una debilidad extrema en cualquiera de los componentes puede reducir considerablemente el resultado global.

55. Indicadores para evaluar un sistema de información

El desempeño puede evaluarse mediante:

Disponibilidad

$$\text{Disponibilidad} = \frac{\text{Tiempo disponible}}{\text{Tiempo total}} \times 100$$

Tiempo de respuesta

$$TR = \text{Tiempo entre solicitud y respuesta}$$

Calidad del dato

$$CD = \frac{\text{Registros correctos}}{\text{Total registros}} \times 100$$

Uso del sistema

$$US = \frac{Usuarios\ activos}{Usuarios\ registrados} \times 100$$

Retorno de inversión

$$ROI = \frac{Beneficio - Costo}{Costo} \times 100$$

Estos indicadores permiten evaluar tanto desempeño técnico como empresarial.

56. Tendencias futuras

Los sistemas de información evolucionarán hacia arquitecturas más:

- integradas;
- automatizadas;
- predictivas;
- inteligentes;
- conectadas;
- basadas en la nube.

Entre las principales tendencias se encuentran:

Inteligencia artificial generativa

Permitirá interactuar con sistemas mediante lenguaje natural.

Analítica aumentada

Automatizará parte de la preparación y análisis de datos.

IoT

Generará grandes cantidades de datos operacionales.

Edge computing

Permitirá procesar información cerca de la fuente.

Digital twins

Simularán procesos físicos mediante representaciones digitales.

Automatización inteligente

Integrará IA con procesos empresariales.

Sistemas autónomos de decisión

Podrán ejecutar determinadas acciones sin intervención humana directa.

Sin embargo, el avance tecnológico deberá acompañarse de mecanismos robustos de gobierno, seguridad y control.

57. Sistemas de información y ventaja competitiva

Los sistemas de información pueden generar ventaja competitiva cuando permiten:

- reducir costos;
- diferenciar productos;
- conocer mejor al cliente;
- mejorar operaciones;
- aumentar velocidad;
- innovar.

Por ejemplo:

Datos del cliente + Analítica

pueden producir:

Personalización

que conduce a:

Mayor satisfacción

y potencialmente:

Mayor fidelización

Pero la tecnología por sí sola puede ser rápidamente imitada. La ventaja sostenible depende de la combinación entre:

Tecnología + Datos + Conocimiento + Procesos + Capacidades

58. Modelo integrado para la toma de decisiones

A partir de los elementos desarrollados puede plantearse un modelo:

Nivel 1. Captura

TPS + IoT + CRM + ERP



Nivel 2. Integración

Base de datos + Data Warehouse



Nivel 3. Visualización

BI + Dashboards



Nivel 4. Analítica

Estadística + Data Mining + ML



Nivel 5. Decisión

Humana + Asistida + Automatizada



Nivel 6. Acción

Implementación



Nivel 7. Retroalimentación

Resultados → Nuevos datos

Este modelo convierte el sistema de información en un ciclo continuo de aprendizaje.

59. Relación con los capítulos anteriores

Los tres primeros capítulos de esta obra conforman una secuencia lógica.

Capítulo 1

Analítica empresarial

Pregunta:

¿Cómo convertir datos en decisiones?

Capítulo 2

Estadística para la gestión operacional

Pregunta:

¿Cómo analizar cuantitativamente los datos?

Capítulo 3

Sistemas de información y toma de decisiones

Pregunta:

¿Cómo recopilar, integrar y distribuir la información necesaria?

Por tanto:

Sistemas de información + Estadística + Analítica

permiten construir:

Decisiones basadas en datos

Esta base será particularmente importante para el siguiente capítulo, dedicado a la **minería de datos para marketing y ventas**, donde se incorporarán algoritmos capaces de descubrir patrones en grandes bases de información empresarial.

60. Conclusiones

Los sistemas de información constituyen una infraestructura fundamental para la gestión empresarial contemporánea. Su relevancia no deriva únicamente de su capacidad para automatizar operaciones, sino de la posibilidad de capturar, integrar, procesar y transformar datos en información útil para diferentes niveles de decisión.

La evolución desde los sistemas transaccionales hacia los sistemas gerenciales, DSS, ERP, CRM, SCM, data warehouses y plataformas de Business Intelligence ha permitido integrar progresivamente las funciones empresariales. Las tecnologías actuales continúan ampliando esta capacidad mediante computación en la nube, Internet de las cosas, big data, aprendizaje automático e inteligencia artificial.

La capacidad de una empresa para obtener valor de estos sistemas depende fundamentalmente de la integración entre tecnología, personas y procesos. Una infraestructura sofisticada puede generar poco impacto si los datos poseen baja calidad, los usuarios carecen de competencias o la información no se encuentra alineada con las necesidades de decisión.

La incorporación de analítica avanzada transforma además la función tradicional de los sistemas de información. Las empresas están pasando progresivamente de sistemas destinados a responder qué ocurrió hacia plataformas capaces de explicar por qué ocurrió, predecir qué podría ocurrir y recomendar qué acciones adoptar.

En este contexto:

Sistema tradicional → Registro,
Sistema gerencial → Información,
Business Intelligence → Comprensión

Machine Learning → Predicción

Inteligencia Artificial → Asistencia a la decisión

No obstante, la mayor dependencia de los sistemas digitales también incrementa riesgos relacionados con ciberseguridad, privacidad, sesgos y gobierno de datos. El NIST Cybersecurity Framework 2.0 refuerza precisamente la necesidad de considerar el riesgo tecnológico dentro de los procesos generales de gobierno y gestión empresarial (Pascoe et al., 2024).

En consecuencia, la verdadera ventaja no consiste simplemente en disponer de más tecnología, sino en desarrollar la capacidad organizacional para convertir información en decisiones oportunas y decisiones en resultados.

La relación fundamental puede sintetizarse mediante:

Datos → Sistemas → Información → Analítica → Decisiones → Acciones → Resultados

Una empresa capaz de mantener este ciclo de forma continua estará mejor preparada para competir en entornos caracterizados por incertidumbre, velocidad y creciente disponibilidad de información.

Referencias bibliográficas

Gronwald, K.-D. (2026). *Integrated business information systems: Linked business process chain ERP, SCM, CRM, BI, big data, and how artificial intelligence influences them*. Springer. <https://doi.org/10.1007/978-3-662-73528-2>

Laudon, K. C., Laudon, J. P., & Traver, C. G. (2025). *Management information systems: Managing the digital firm* (18th ed.). Pearson.

National Institute of Standards and Technology. (2024). *The NIST Cybersecurity Framework (CSF) 2.0* (NIST CSWP 29). U.S. Department of Commerce. <https://doi.org/10.6028/NIST.CSWP.29>

Organization for Economic Co-operation and Development. (2024a). *OECD Digital Economy Outlook 2024: Volume 1—Embracing the technology frontier*. OECD Publishing.

Organization for Economic Co-operation and Development. (2024b). *SME digitalisation 2024: Managing shocks and transitions—An OECD D4SME survey*. OECD.

Pascoe, C., Quinn, S., & Scarfone, K. (2024). *The NIST Cybersecurity Framework (CSF) 2.0*. National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.CSWP.29>

Quinn, S., Pascoe, C., Barrett, M., Scarfone, K., & Witte, G. (2024). *NIST Cybersecurity Framework 2.0: Quick-start guide for using the CSF tiers* (NIST SP 1302). National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.SP.1302>

Sharda, R., Delen, D., & Turban, E. (2024). *Business intelligence, analytics, data science, and AI* (5th ed., Global ed.). Pearson.

CAPÍTULO 4

Minería de datos para marketing y ventas

Milton Fabian Peñaherrera Larenas

mpenaherrera@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0000-0001-8603-7522>

1. Introducción

La minería de datos constituye una de las herramientas más importantes para transformar grandes volúmenes de información comercial en conocimiento útil para la toma de decisiones. En marketing y ventas, su aplicación permite identificar patrones de compra, segmentar clientes, anticipar comportamientos, detectar oportunidades comerciales y diseñar estrategias más precisas.

La disponibilidad de datos provenientes de sistemas CRM, plataformas de comercio electrónico, redes sociales, campañas digitales, historial de compras y sistemas ERP ha incrementado significativamente las posibilidades de análisis. Sin embargo, disponer de información no es suficiente. Es necesario aplicar técnicas capaces de descubrir relaciones que no siempre son evidentes mediante un análisis tradicional.

La minería de datos puede definirse como el proceso de identificar patrones, relaciones y regularidades relevantes dentro de grandes conjuntos de datos. En el contexto empresarial, se integra con estadística, aprendizaje automático, inteligencia artificial y analítica empresarial para apoyar decisiones basadas en evidencia.

En marketing y ventas, este proceso puede representarse como:

*Datos del cliente → Minería de datos → Patrones → Predicciones
→ Decisiones comerciales*

De esta manera, las organizaciones pueden pasar de estrategias generales hacia acciones personalizadas y orientadas a segmentos específicos.

2. Minería de datos y marketing

El marketing moderno genera múltiples fuentes de información:

- compras realizadas;
- frecuencia de compra;
- monto gastado;
- productos preferidos;
- interacciones digitales;
- respuesta a promociones;
- visitas a sitios web;
- reclamaciones;

- ubicación;
- características sociodemográficas.

La minería de datos permite analizar conjuntamente estas variables para responder preguntas como:

¿Qué clientes tienen mayor probabilidad de comprar nuevamente?

¿Qué productos suelen adquirirse juntos?

¿Qué segmentos presentan mayor rentabilidad?

¿Qué clientes están en riesgo de abandonar la empresa?

¿Qué características tienen los clientes que responden positivamente a una campaña?

Estas preguntas transforman la minería de datos en una herramienta estratégica para marketing.

3. Proceso CRISP-DM

Una de las metodologías más utilizadas en proyectos de minería de datos es **CRISP-DM**, que organiza el proceso en seis etapas:

1. comprensión del negocio;
2. comprensión de los datos;
3. preparación de los datos;
4. modelado;
5. evaluación;
6. despliegue.

El proceso puede representarse como:

Negocio → Datos → Preparación → Modelado → Evaluación → Implementación

La metodología mantiene vigencia porque obliga a comenzar por el problema empresarial y no por el algoritmo.

En marketing, por ejemplo, el objetivo no debería formularse simplemente como:

“Aplicar una red neuronal”.

Sería más apropiado:

“Identificar clientes con alta probabilidad de responder a una campaña comercial”.

El algoritmo es una herramienta y no el objetivo del análisis.

4. Preparación de datos comerciales

Antes de aplicar cualquier técnica, los datos deben ser preparados.

Las principales actividades incluyen:

- eliminar duplicados;
- corregir inconsistencias;
- tratar valores faltantes;
- transformar variables;
- identificar valores atípicos;
- seleccionar variables relevantes;
- normalizar cuando sea necesario.

Por ejemplo, una base de clientes podría contener:

Variable	Tipo
Edad	Numérica
Ingreso	Numérica
Frecuencia de compra	Numérica
Ciudad	Categórica
Producto preferido	Categórica
Compra reciente	Sí/No

Una preparación deficiente puede producir resultados engañosos.

Por ello:

$$\text{Calidad del modelo} \leq \text{Calidad de los datos}$$

5. Segmentación de clientes

Uno de los principales usos de la minería de datos en marketing consiste en identificar grupos de clientes con comportamientos similares.

La segmentación tradicional suele basarse en variables como:

- edad;
- sexo;
- ubicación;
- nivel de ingresos.

La segmentación basada en datos puede incorporar:

- frecuencia de compra;
- recencia;
- ticket promedio;

- respuesta a promociones;
- rentabilidad;
- categorías adquiridas.

Esto permite construir segmentos más útiles desde una perspectiva comercial.

6. Clustering

El **clustering** agrupa observaciones similares sin utilizar previamente una variable objetivo.

Uno de los algoritmos más utilizados es **K-means**.

El objetivo consiste en minimizar:

$$J = \sum_{j=1}^k \sum_{x_i \in C_j} \|x_i - \mu_j\|^2$$

donde:

- k : número de grupos;
- C_j : grupo;
- μ_j : centroide.

Una empresa podría obtener:

Segmento 1

Clientes frecuentes y de alto gasto.

Segmento 2

Clientes ocasionales.

Segmento 3

Clientes nuevos.

Segmento 4

Clientes con baja actividad.

A partir de ello pueden definirse estrategias diferentes.

7. Análisis RFM

El análisis **RFM** es ampliamente utilizado para segmentar clientes.

RFM significa:

$R = \text{Recency}$
 $F = \text{Frequency}$
 $M = \text{Monetary}$

Recencia

¿Cuánto tiempo ha pasado desde la última compra?

Frecuencia

¿Cuántas compras realizó el cliente?

Valor monetario

¿Cuánto dinero ha gastado?

Puede expresarse:

$$RFM = f(R, F, M)$$

Un cliente con alta frecuencia, compras recientes y elevado valor monetario puede considerarse estratégico.

8. Ejemplo de RFM

Considérese:

Cliente	Recencia	Frecuencia	Monto
A	5 días	12	\$2.500
B	80 días	2	\$300
C	15 días	8	\$1.600

El cliente A presenta mejores indicadores generales.

Las empresas pueden asignar puntuaciones entre 1 y 5 a cada dimensión.

Por ejemplo:

$$R = 5, F = 5, M = 5$$

sería un cliente de alto valor.

9. Reglas de asociación

Las reglas de asociación permiten identificar productos que suelen adquirirse conjuntamente.

Ejemplo:

$$\text{Pan} \rightarrow \text{Leche}$$

Esto significa que quienes compran pan también presentan cierta probabilidad de comprar leche. Tres indicadores son especialmente importantes.

Soporte

$$Support(A \rightarrow B) = P(A \cap B)$$

Confianza

$$Confidence(A \rightarrow B) = P(B | A)$$

Lift

$$Lift = \frac{P(A \cap B)}{P(A)P(B)}$$

Si:

$$Lift > 1$$

existe una asociación positiva.

10. Market Basket Analysis

El análisis de cesta de mercado utiliza reglas de asociación para identificar patrones de compra.

Puede ayudar a decidir:

- ubicación de productos;
- promociones conjuntas;
- recomendaciones;
- paquetes comerciales.

Por ejemplo:

$$Café \rightarrow Azúcar$$

Si la asociación es fuerte, la empresa podría ofrecer:

“Compre café y obtenga descuento en azúcar”.

Este tipo de análisis es especialmente relevante en supermercados, comercio electrónico y retail.

11. Clasificación

La clasificación intenta predecir categorías previamente definidas.

Ejemplos:

$$\begin{aligned} Compra &= \acute{S}i/No \\ Cliente\ rentable &= \acute{S}i/No \\ Abandono &= \acute{S}i/No \end{aligned}$$

Entre los algoritmos utilizados se encuentran:

- regresión logística;
- árboles de decisión;
- Random Forest;
- redes neuronales;
- máquinas de vectores de soporte.

12. Predicción de compra

Supóngase que una empresa quiere estimar:

$$P(Compra = 1)$$

utilizando:

- edad;
- ingreso;
- frecuencia;
- monto;
- promociones utilizadas.

Una regresión logística puede expresarse como:

$$P(Y = 1) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}}$$

Si un cliente obtiene:

$$P(Compra = 1) = 0.82$$

la empresa podría priorizarlo dentro de una campaña.

13. Árboles de decisión

Los árboles de decisión permiten construir reglas fácilmente interpretables.

Ejemplo:

¿Frecuencia > 5 compras?

Sí →

¿Ticket > \$100?

Sí →

Ciente de alto valor

La principal ventaja es su facilidad de interpretación.

Esto resulta especialmente útil cuando los gerentes necesitan comprender cómo se genera una predicción.

14. Random Forest

Random Forest combina múltiples árboles de decisión.

En lugar de depender de un único árbol:

$$\begin{array}{c} \text{'} \\ \text{Arbol}_1 \\ \text{'} \\ \text{Arbol}_2 \\ \dots \\ \text{'} \\ \text{Arbol}_n \end{array}$$

se realiza una predicción agregada.

Este procedimiento puede mejorar la estabilidad y capacidad predictiva.

En marketing puede emplearse para:

- predecir compras;
- identificar churn;
- clasificar clientes;
- evaluar importancia de variables.

15. Redes neuronales

Las redes neuronales permiten identificar relaciones complejas y no lineales.

Una estructura sencilla incluye:

Entrada → Capa oculta → Salida

Las entradas pueden ser:

- edad;
- ingreso;
- frecuencia;

- promociones;
- historial de compra.

La salida podría ser:

$$Compra = \hat{S}_i / No$$

Su principal ventaja es la capacidad de modelar relaciones complejas, aunque generalmente son menos interpretables que un árbol de decisión.

16. Predicción de abandono de clientes

El **churn** representa la pérdida o abandono de clientes.

Puede definirse:

$$Churn = \frac{Clientes\ perdid\os}{Clientes\ iniciales} \times 100$$

Si una empresa inicia con 1.000 clientes y pierde 80:

$$Churn = \frac{80}{1000} \times 100$$

$$Churn = 8\%$$

Los modelos predictivos permiten identificar quién presenta mayor probabilidad de abandono.

Variables frecuentes:

- disminución de compras;
- quejas;
- antigüedad;
- frecuencia;
- recencia;
- problemas de servicio.

17. Evaluación de modelos

Un modelo debe evaluarse antes de ser utilizado comercialmente.

Para clasificación se utiliza la matriz de confusión.

	Predicho Sí	Predicho No
Real Sí	VP	FN
Real No	FP	VN

A partir de ella pueden calcularse varias métricas.

18. Accuracy

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN}$$

Indica la proporción total de predicciones correctas.

Sin embargo, puede ser engañosa en bases desbalanceadas.

Por ejemplo, si únicamente el 5 % de clientes abandona, un algoritmo que prediga “no abandono” para todos tendría 95 % de accuracy, pero sería poco útil.

19. Precision

$$Precision = \frac{VP}{VP + FP}$$

Indica qué proporción de los casos identificados como positivos realmente lo son.

En marketing responde:

De los clientes que predije que comprarían, ¿cuántos realmente compraron?

20. Recall

$$Recall = \frac{VP}{VP + FN}$$

Responde:

De todos los clientes que realmente compraron, ¿cuántos logró identificar el modelo?

Es especialmente importante cuando perder casos positivos resulta costoso.

21. F1-score

Combina precisión y recall.

$$F1 = 2 \frac{Precision \times Recall}{Precision + Recall}$$

Es útil cuando las clases no están equilibradas.

22. ROC-AUC

La curva ROC compara:

Sensibilidad

frente a:

$1 - \text{Especificidad}$

El área bajo la curva:

AUC

mide la capacidad del modelo para discriminar entre clases.

Valores más cercanos a 1 indican mejor discriminación.

23. Minería de datos en ventas

En ventas puede utilizarse para:

- priorizar prospectos;
- estimar probabilidad de cierre;
- pronosticar ventas;
- identificar vendedores de alto desempeño;
- recomendar productos;
- detectar oportunidades de venta cruzada.

Por ejemplo:

$$P(\text{Cierre}) = f(\text{Cliente}, \text{Producto}, \text{Vendedor}, \text{Precio}, \text{Historial})$$

Los prospectos con mayor probabilidad pueden recibir atención prioritaria.

24. Cross-selling y up-selling

Cross-selling

Consiste en ofrecer productos complementarios.

Ejemplo:

Laptop → Mouse

Up-selling

Consiste en ofrecer una versión de mayor valor.

Ejemplo:

Plan básico → Plan premium

La minería de datos permite identificar qué productos son más apropiados para cada cliente.

25. Marketing personalizado

La personalización se basa en comprender el comportamiento individual.

Puede utilizar:

Historial + Segmentación + Predicción

para generar:

Oferta personalizada

Por ejemplo, una plataforma puede recomendar productos en función de compras anteriores y comportamiento de clientes similares.

26. Caso aplicado

Considérese una empresa con 5.000 clientes.

Variables:

Variable	Descripción
Edad	Edad
Ingreso	Ingreso mensual
Frecuencia	Compras por año
Ticket	Compra promedio
Recencia	Días desde última compra
Promociones	Promociones utilizadas
Compra	Sí/No

El objetivo es predecir:

Compra

La empresa divide los datos en:

*70% entrenamiento
30% prueba*

y compara varios algoritmos.

27. Resultados hipotéticos

Modelo	Accuracy	F1	AUC
Regresión logística	0,82	0,79	0,85
Árbol de decisión	0,80	0,77	0,81
Random Forest	0,87	0,85	0,91
Red neuronal	0,88	0,86	0,92

En este ejemplo, la red neuronal presenta el mejor desempeño general.


Sin embargo, la selección final debe considerar también:


- interpretabilidad;
- costo;
- facilidad de implementación;
- estabilidad;
- utilidad comercial.

28. Aplicación en Orange

Orange constituye una herramienta visual que permite desarrollar modelos de minería de datos sin necesidad de programación avanzada.

Un flujo básico puede ser:





Este enfoque resulta especialmente apropiado para estudiantes de administración, comercio y áreas afines que están iniciándose en aprendizaje automático.

29. Uso de Rank

El widget **Rank** permite identificar qué variables aportan mayor información para predecir la variable objetivo.

Por ejemplo:

Variable	Importancia
Frecuencia	0,89
Recencia	0,82
Ticket	0,76
Promociones	0,60
Edad	0,30

Esto permite identificar factores comerciales relevantes.

No debe interpretarse automáticamente como causalidad.

30. Ética y privacidad

El análisis de clientes plantea importantes desafíos.

Las empresas deben evitar:

- uso indebido de datos;
- discriminación;
- invasión de privacidad;
- perfiles injustificados;
- decisiones opacas.

La información debe utilizarse con criterios de:

Legalidad + Transparencia + Seguridad + Responsabilidad

Un modelo comercial puede ser técnicamente preciso y, sin embargo, resultar cuestionable si utiliza datos sensibles de forma inapropiada.

31. Beneficios empresariales

La minería de datos puede contribuir a:

- incrementar conversión;
- reducir abandono;
- mejorar segmentación;
- optimizar campañas;
- identificar clientes rentables;
- pronosticar ventas;
- mejorar promociones;
- aumentar fidelización.

Puede expresarse:

Valor comercial

*= Mejor información + Mejor segmentación + Mejor predicción
+ Mejor decisión*

32. Limitaciones

La minería de datos también presenta limitaciones:

- datos de baja calidad;
- modelos sobreajustados;
- poca interpretabilidad;
- cambios en el comportamiento del cliente;
- sesgos;
- dependencia de información histórica.

Un modelo que funcionó bien durante un período puede deteriorarse con el tiempo.

Por ello es necesario realizar:

Monitoreo → Evaluación → Reentrenamiento

33. Tendencias actuales

Las tendencias más importantes incluyen:

- inteligencia artificial generativa;
- sistemas de recomendación;
- analítica en tiempo real;
- customer intelligence;
- marketing predictivo;
- automatización de campañas;
- personalización avanzada;
- integración entre CRM e IA.

La evolución puede representarse:



34. Conclusiones

La minería de datos constituye una herramienta estratégica para marketing y ventas porque permite descubrir patrones, segmentar clientes y anticipar comportamientos comerciales.

Técnicas como clustering, análisis RFM, reglas de asociación, regresión logística, árboles de decisión, Random Forest y redes neuronales ofrecen diferentes perspectivas para analizar el mercado y mejorar las decisiones.

Su aplicación permite avanzar desde una gestión basada en información histórica hacia estrategias comerciales predictivas y personalizadas.

Sin embargo, el éxito de un proyecto de minería de datos depende no solamente del desempeño de los algoritmos. También requiere datos de calidad, objetivos empresariales claramente definidos, evaluación adecuada y una interpretación orientada a decisiones.

Por tanto:

Datos → Patrones → Predicción → Segmentación → Acción → Resultado

La minería de datos transforma así la información comercial en una fuente de conocimiento capaz de incrementar la eficiencia y efectividad de las estrategias de marketing y ventas.

Referencias bibliográficas

Aggarwal, C. C. (2023). *Data mining: The textbook* (2nd ed.). Springer.

Han, J., Pei, J., & Tong, H. (2022). *Data mining: Concepts and techniques* (4th ed.). Morgan Kaufmann.

IBM. (2026). *CRISP-DM help overview*. IBM Documentation.

James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). *An introduction to statistical learning: With applications in Python*. Springer. <https://doi.org/10.1007/978-3-031-38747-0>

Kotu, V., & Deshpande, B. (2019). *Data science: Concepts and practice* (2nd ed.). Morgan Kaufmann.

Provost, F., & Fawcett, T. (2013). *Data science for business: What you need to know about data mining and data-analytic thinking*. O'Reilly Media.

Sharda, R., Delen, D., & Turban, E. (2024). *Business intelligence, analytics, data science, and AI* (5th ed.). Pearson.

Shmueli, G., Bruce, P. C., Gedeck, P., & Patel, N. R. (2023). *Data mining for business analytics: Concepts, techniques, and applications in Python*. Wiley.

CAPÍTULO 5

Modelos predictivos para negocios

Nelson David Moreira Macias

nmoreira@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0000-0003-3608-1618>

1. Introducción

Los modelos predictivos constituyen una de las aplicaciones más relevantes de la analítica empresarial, debido a que permiten utilizar datos históricos para estimar comportamientos futuros. En el contexto de los negocios, esta capacidad resulta especialmente valiosa para anticipar ventas, demanda, riesgo crediticio, abandono de clientes, probabilidad de compra, fallas operativas y comportamiento financiero.

A diferencia de la analítica descriptiva, que explica qué ocurrió, la analítica predictiva busca responder:

¿Qué es probable que ocurra?

El proceso puede representarse como:

Datos históricos → Modelo → Predicción → Decisión

La construcción de modelos predictivos integra estadística, aprendizaje automático, minería de datos e inteligencia artificial. James et al. (2023) señalan que los modelos de aprendizaje estadístico permiten relacionar variables predictoras con una variable objetivo para explicar o anticipar su comportamiento.

En el ámbito empresarial, su utilidad depende no solamente de la precisión estadística, sino también de la capacidad del modelo para apoyar decisiones concretas y generar valor.

2. Concepto de modelo predictivo

Un modelo predictivo es una representación matemática o algorítmica que utiliza variables de entrada para estimar una variable de salida.

Puede expresarse como:

$$Y = f(X_1, X_2, \dots, X_k)$$

donde:

- Y : variable objetivo;
- $X_1, X_2, \dots, X_k$: variables predictoras.

Por ejemplo:

$$Ventas = f(Precio, Promoción, Temporada, Demanda)$$

o:

$$\text{Riesgo de impago} = f(\text{Ingreso}, \text{Deuda}, \text{Historial}, \text{Carga financiera})$$

El objetivo consiste en aprender relaciones presentes en los datos y utilizarlas en nuevos casos.

3. Predicción y clasificación

Los modelos predictivos pueden dividirse en dos grandes grupos.

3.1. Predicción de valores continuos

Se utiliza cuando la variable objetivo es numérica.

Ejemplos:

- ventas;
- ingresos;
- demanda;
- costos;
- tiempo de entrega.

En estos casos suelen utilizarse modelos de regresión.

3.2. Clasificación

Se utiliza cuando la variable objetivo es categórica.

Ejemplos:

Compra = Sí/No
Crédito = Aprobado/Rechazado
Cliente = Activo/Inactivo
Riesgo = Alto/Medio/Bajo

En estos casos pueden emplearse regresión logística, árboles de decisión, Random Forest, redes neuronales y otros algoritmos.

4. Flujo de un proyecto predictivo

Un proyecto puede organizarse mediante:

1. definición del problema;
2. selección de datos;
3. preparación;

4. división de la muestra;
5. entrenamiento;
6. evaluación;
7. comparación;
8. implementación.

Puede representarse como:

Problema → Datos → Preparación → Entrenamiento → Evaluación → Predicción

El objetivo empresarial debe definirse antes de seleccionar el algoritmo.

Por ejemplo, no es suficiente afirmar:

“Se aplicará Random Forest”.

Es más adecuado establecer:

“Se estimará la probabilidad de que un cliente abandone la empresa durante los próximos tres meses”.

5. Variables predictoras y variable objetivo

La variable objetivo representa aquello que se desea predecir.

Ejemplo:

$$Y = \text{Compra}$$

Las variables predictoras podrían ser:

$$\begin{aligned} X_1 &= \text{Edad} \\ X_2 &= \text{Ingreso} \\ X_3 &= \text{Frecuencia} \\ X_4 &= \text{Promociones} \\ X_5 &= \text{Recencia} \end{aligned}$$

La selección adecuada de variables es fundamental.

Variables irrelevantes pueden introducir ruido y reducir el desempeño.

6. División entrenamiento-prueba

Una práctica fundamental consiste en dividir los datos.

Por ejemplo:

$$\begin{aligned} &70\% \text{ Entrenamiento} \\ &30\% \text{ Prueba} \end{aligned}$$

El conjunto de entrenamiento se utiliza para construir el modelo.

El conjunto de prueba evalúa su capacidad para predecir casos no observados.

James et al. (2023) destacan la importancia de evaluar los modelos con datos distintos de aquellos utilizados para entrenarlos.

7. Regresión lineal

La regresión lineal es uno de los modelos predictivos más utilizados cuando la variable objetivo es continua.

Su forma general es:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_k + \epsilon$$

Por ejemplo:

$$Ventas = \beta_0 + \beta_1(Publicidad) + \beta_2(Precio) + \beta_3(Promociones) + \epsilon$$

El modelo estima el efecto conjunto de las variables predictoras.

8. Ejemplo de regresión

Supóngase:

$$Ventas = 5000 + 2.5(Publicidad) - 300(Precio)$$

Si:

$$Publicidad = 2000$$

y:

$$Precio = 15$$

entonces:

$$\begin{aligned} Ventas &= 5000 + 2.5(2000) - 300(15) \\ Ventas &= 5500 \end{aligned}$$

El resultado corresponde a la predicción bajo el modelo estimado.

9. Regresión logística

La regresión logística se utiliza cuando la variable objetivo es binaria.

Por ejemplo:

$$Compra = \begin{cases} 1 & \text{Si} \\ 0 & \text{No} \end{cases}$$

La probabilidad se estima mediante:

$$P(Y = 1) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}}$$

El resultado puede interpretarse como:

$$P(Compra) = 0.78$$

Esto significa que el cliente presenta una probabilidad estimada del 78 % de comprar, según el modelo.

10. Árboles de decisión

Los árboles de decisión generan reglas a partir de divisiones sucesivas.

Ejemplo:

¿Ingreso > \$1.500?

Sí →

¿Frecuencia > 5?

Sí →

Alta probabilidad de compra

No →

Probabilidad media

La principal ventaja de los árboles es su interpretabilidad.

También pueden utilizarse para problemas de regresión.

11. Random Forest

Random Forest combina múltiples árboles.

El procedimiento puede representarse:

$$\hat{Arbol}_1 + \hat{Arbol}_2 + \dots + \hat{Arbol}_n$$

↓

Predicción agregada

Esto permite reducir la inestabilidad que puede presentar un árbol individual.

Shmueli et al. (2023) destacan el uso de técnicas de ensamble dentro de la analítica predictiva empresarial debido a su capacidad para mejorar el desempeño en múltiples problemas.

12. Redes neuronales

Las redes neuronales están inspiradas en estructuras de procesamiento interconectadas.

Una red básica contiene:

Capa de entrada



Capa oculta



Capa de salida

En negocios pueden utilizarse para:

- ventas;
- fraude;
- riesgo;
- clasificación;
- abandono;
- demanda.

Su fortaleza radica en modelar relaciones no lineales complejas.

Su limitación principal es la menor interpretabilidad.

13. Máquinas de vectores de soporte

Las **Support Vector Machines (SVM)** buscan encontrar una frontera que separe diferentes clases.

Para dos grupos:

Clase A

y:

Clase B

el algoritmo busca maximizar el margen entre ambas.

Puede utilizarse en:

- detección de fraude;
- clasificación de clientes;
- riesgo crediticio;
- análisis de comportamiento.

Su desempeño puede ser alto, aunque requiere una adecuada configuración de parámetros.

14. Modelos de series temporales

Cuando los datos dependen del tiempo pueden utilizarse modelos específicos.

Ejemplos:

- ventas mensuales;
- demanda;
- precios;
- flujo de caja;
- consumo.

Una serie temporal puede representarse mediante:

$$Y_t = T_t + S_t + C_t + I_t$$

donde:

- T_t : tendencia;
- S_t : estacionalidad;
- C_t : ciclo;
- I_t : componente irregular.

Hyndman y Athanasopoulos (2021) destacan la importancia de identificar estos componentes para construir pronósticos adecuados.

15. Promedio móvil

Un modelo sencillo es:

$$\hat{Y}_{t+1} = \frac{Y_t + Y_{t-1} + \dots + Y_{t-k+1}}{k}$$

Si las ventas de los últimos tres meses fueron:

1000, 1200, 1400

entonces:

$$\hat{Y}_{t+1} = \frac{1000 + 1200 + 1400}{3}$$
$$\hat{Y}_{t+1} = 1200$$

16. Suavización exponencial

Puede utilizarse:

$$F_{t+1} = \alpha Y_t + (1 - \alpha)F_t$$

donde:

- F_{t+1} : nuevo pronóstico;
- Y_t : valor actual;
- F_t : pronóstico previo;
- α : parámetro.

Este modelo asigna mayor o menor peso a los valores recientes.

17. Métricas de regresión

Cuando se predicen valores continuos pueden utilizarse diferentes métricas.

MAE

$$MAE = \frac{1}{n} \sum |Y_i - \hat{Y}_i|$$

MSE

$$MSE = \frac{1}{n} \sum (Y_i - \hat{Y}_i)^2$$

RMSE

$$RMSE = \sqrt{MSE}$$

R^2

$$R^2 = 1 - \frac{\sum (Y_i - \hat{Y}_i)^2}{\sum (Y_i - \bar{Y})^2}$$

Los valores más bajos de error suelen indicar mejores predicciones.

18. Métricas de clasificación

Para clasificación pueden utilizarse:

Accuracy

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN}$$

Precision

$$Precision = \frac{VP}{VP + FP}$$

Recall

$$Recall = \frac{VP}{VP + FN}$$

F1

$$F1 = 2 \frac{Precision \times Recall}{Precision + Recall}$$

Estas métricas deben seleccionarse según el problema empresarial.

19. Importancia del contexto empresarial

No siempre la métrica más alta representa el mejor modelo.

Por ejemplo, en fraude financiero puede ser más importante detectar la mayor cantidad de casos fraudulentos.

En ese contexto:

Recall

puede ser más importante que:

Accuracy

En cambio, si una empresa quiere evitar enviar promociones costosas a clientes incorrectos:

Precision

puede recibir mayor importancia.

20. Overfitting

El **sobreajuste** ocurre cuando el modelo aprende demasiado bien los datos de entrenamiento, incluyendo ruido.

Puede ocurrir:

$$Accuracy_{train} = 99\%$$

pero:

$$Accuracy_{test} = 70\%$$

Esto significa que el modelo no generaliza adecuadamente.

La solución puede incluir:

- validación cruzada;
- regularización;
- reducción de variables;
- más datos;
- modelos menos complejos.

21. Underfitting

El **subajuste** ocurre cuando el modelo es demasiado simple.

Por ejemplo:

$$\begin{aligned} Accuracy_{train} &= 65\% \\ Accuracy_{test} &= 64\% \end{aligned}$$

Esto puede indicar que el modelo no capta adecuadamente la estructura de los datos.

La solución puede requerir:

- más variables;
- modelos más flexibles;
- transformaciones;
- mejores características.

22. Validación cruzada

La validación cruzada divide los datos en varios grupos.

Por ejemplo:

$$k = 5$$

Cada grupo se utiliza una vez como prueba y el resto como entrenamiento.

Esto permite obtener una evaluación más estable del modelo.

James et al. (2023) consideran la validación cruzada una herramienta esencial para estimar el error de predicción.

23. Selección de variables

No siempre más variables producen mejores modelos.

Puede utilizarse:

- correlación;
- importancia de variables;
- selección automática;
- regularización;
- conocimiento del negocio.

Un modelo más simple puede ser preferible si ofrece rendimiento similar.

La selección debe equilibrar:

$$\textit{Precisión} + \textit{Interpretabilidad} + \textit{Simplicidad}$$

24. Importancia de variables

Los modelos pueden indicar cuáles variables influyen más en la predicción.

Ejemplo:

Variable	Importancia
Frecuencia	0,89
Recencia	0,81
Ticket	0,76
Edad	0,32

Esto puede aportar información estratégica.

Sin embargo:

$$\textit{Importancia predictiva} \neq \textit{Causalidad}$$

Una variable puede predecir bien sin ser causa directa.

25. Aplicaciones empresariales

Los modelos predictivos pueden utilizarse en múltiples áreas.

Área	Aplicación
Marketing	Probabilidad de compra
Ventas	Pronóstico
Finanzas	Riesgo crediticio
RRHH	Rotación
Operaciones	Demanda
Logística	Tiempo de entrega
Mantenimiento	Probabilidad de falla
Servicio	Abandono de clientes

26. Predicción de ventas

Un modelo puede estimar:

$$Ventas_{t+1} = f(V, e, n, t, a, s_t, Precio, Publicidad, Temporada, Promociones)$$

Esta información permite planificar:

- inventarios;
- personal;
- compras;
- presupuesto;
- producción.

27. Predicción del riesgo crediticio

Una institución financiera puede estimar:

$$P(\text{Impago}) = f(I, n, g, reso, Deuda, Historial, Antigüedad)$$

Por ejemplo:

$$P(\text{Impago}) = 0.72$$

El resultado puede utilizarse dentro de un sistema de apoyo a decisiones.

Sin embargo, este tipo de modelos requiere especial cuidado respecto de sesgos, discriminación y regulación.

28. Predicción de demanda

Puede modelarse:

$$Demanda = f(P, r, e, cioTemporadaPromociónHistórico)$$

Una buena predicción permite reducir:

Sobreinventario

y:

Ruptura de stock

Esto genera beneficios económicos y operativos.

29. Predicción de abandono

El churn puede estimarse mediante:

$$P(Churn) = f(R, e, c, enciaFrecuenciaQuejasAntigüedad)$$

Los clientes con alta probabilidad pueden ser priorizados.

Ejemplo:

$$P(Churn) > 0.75$$

↓

Campaña de retención

30. Modelos predictivos y Orange

Orange permite implementar modelos mediante una interfaz visual.

Un flujo básico puede contener:


File

↓

Select Columns

↓

Impute



Entre los algoritmos disponibles pueden encontrarse:

- Logistic Regression;
- Tree;
- Random Forest;
- Neural Network;
- SVM.

31. Comparación de modelos

Supóngase el siguiente resultado:

Modelo	Accuracy	F1	AUC
Logistic Regression	0,81	0,78	0,84
Decision Tree	0,79	0,75	0,80
Random Forest	0,87	0,85	0,91
Neural Network	0,89	0,87	0,93

En este ejemplo, la red neuronal presenta mejor desempeño global.

Sin embargo, podría preferirse Random Forest si se requiere mayor interpretación.

32. Caso aplicado

Considérese una empresa que desea predecir si un cliente realizará una compra.

Variables:

Variable	Descripción
Edad	Edad del cliente
Ingreso	Ingreso mensual
Frecuencia	Compras realizadas
Ticket	Compra promedio
Recencia	Días desde última compra
Promociones	Número utilizado
Compra	Sí/No

La variable objetivo es:

Compra

Los datos se dividen:

70% *entrenamiento*
30% *prueba*

Se entrenan diferentes algoritmos y se selecciona el de mejor desempeño.

33. Interpretación empresarial

Supóngase que un cliente obtiene:

$$P(Compra) = 0.91$$

La empresa podría:

- enviar una oferta personalizada;
- priorizarlo en una campaña;
- recomendar productos;
- asignarlo a un vendedor.

Otro cliente obtiene:

$$P(Compra) = 0.18$$

La empresa podría evitar invertir en una campaña costosa dirigida a ese perfil.

Así:

Predicción → Segmentación → Acción

34. Ética y explicabilidad

Los modelos predictivos también presentan riesgos.

Entre ellos:

- discriminación;
- sesgos;
- decisiones opacas;
- privacidad;
- uso indebido de información.

Por ello, un modelo empresarial debería evaluarse mediante:

Precisión + Equidad + Transparencia + Responsabilidad

La explicabilidad resulta especialmente importante en decisiones que pueden afectar personas, como crédito, contratación o seguros.

35. Limitaciones

Entre las principales limitaciones se encuentran:

- calidad de datos;
- cambios del entorno;
- sobreajuste;
- sesgos;
- poca interpretabilidad;
- dependencia de datos históricos.

Un modelo debe actualizarse cuando cambian las condiciones del mercado.

Por ello:

Entrenar → Evaluar → Implementar → Monitorear → Actualizar

36. Tendencias actuales

Los modelos predictivos están evolucionando mediante:

- AutoML;

- inteligencia artificial generativa;
- aprendizaje profundo;
- modelos en tiempo real;
- explicabilidad;
- integración con BI;
- automatización de decisiones.

La tendencia consiste en integrar:

Datos + Machine Learning + IA + Business Intelligence

para construir sistemas empresariales más inteligentes.

37. Conclusiones

Los modelos predictivos permiten transformar datos históricos en estimaciones útiles sobre comportamientos futuros. Su aplicación en negocios abarca ventas, marketing, finanzas, operaciones, recursos humanos y gestión de riesgos.

Herramientas como regresión lineal, regresión logística, árboles de decisión, Random Forest, redes neuronales y modelos de series temporales ofrecen diferentes alternativas dependiendo del tipo de problema.

La selección del modelo debe considerar no solamente métricas estadísticas, sino también interpretabilidad, costo de implementación y utilidad empresarial.

Asimismo, es fundamental prevenir problemas como sobreajuste, sesgos y pérdida de capacidad predictiva.

En términos generales:

Datos → Modelo → Predicción → Decisión → Resultado

Por ello, los modelos predictivos constituyen uno de los principales puentes entre la ciencia de datos y la gestión empresarial.

Referencias bibliográficas

- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts.
- James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). *An introduction to statistical learning: With applications in Python*. Springer. <https://doi.org/10.1007/978-3-031-38747-0>
- Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling*. Springer.
- Provost, F., & Fawcett, T. (2013). *Data science for business: What you need to know about data mining and data-analytic thinking*. O'Reilly Media.
- Sharda, R., Delen, D., & Turban, E. (2024). *Business intelligence, analytics, data science, and AI* (5th ed.). Pearson.

Shmueli, G., Bruce, P. C., Gedeck, P., & Patel, N. R. (2023). *Data mining for business analytics: Concepts, techniques, and applications in Python*. Wiley.

CAPÍTULO 6

Inteligencia de negocios

Iván Ruben Ruiz Parrales

iruiz@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0000-0001-8644-0629>

Manuel Francisco Flores Valero

mfloresv@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0000-0002-5464-1677>

1. Introducción

La inteligencia de negocios, conocida internacionalmente como **Business Intelligence (BI)**, comprende el conjunto de procesos, tecnologías y herramientas que permiten recopilar, integrar, analizar y visualizar información empresarial para apoyar la toma de decisiones.

Su propósito principal consiste en transformar datos dispersos en información útil y comprensible para directivos, gerentes y responsables de áreas funcionales. En este sentido, la inteligencia de negocios constituye un puente entre los sistemas de información tradicionales y la analítica avanzada.

El proceso puede representarse como:

Datos → Integración → Análisis → Visualización → Decisión

La BI permite responder preguntas como:

¿Qué productos generan mayor rentabilidad?

¿Qué sucursales cumplen las metas?

¿Cuál es la evolución de las ventas?

¿Qué clientes concentran mayor valor?

¿Dónde existen desviaciones operativas?

Por ello, su aplicación se ha extendido a áreas como finanzas, marketing, ventas, operaciones, recursos humanos y logística.

2. Concepto de inteligencia de negocios

La inteligencia de negocios puede definirse como un conjunto de metodologías, arquitecturas y tecnologías destinadas a convertir datos organizacionales en información que facilite decisiones oportunas.

Sharda, Delen y Turban (2024) relacionan la inteligencia de negocios con analítica, ciencia de datos e inteligencia artificial, destacando que las organizaciones modernas utilizan estos enfoques de manera integrada.

De forma conceptual:

$$BI = f(D, a, t, osTecnologíaProcesosUsuarios)$$

La tecnología es importante, pero no suficiente. Una organización puede disponer de herramientas de BI y no obtener valor si los datos son incorrectos o los usuarios no interpretan adecuadamente los indicadores.

3. Diferencia entre BI y analítica empresarial

Aunque ambos conceptos están relacionados, presentan diferencias.

Business Intelligence

Se concentra principalmente en:

- monitoreo;
- visualización;
- reporting;
- indicadores;
- análisis histórico.

Responde principalmente:

¿Qué ocurrió?

y:

¿Cómo estamos funcionando?

Business Analytics

Avanza hacia:

- diagnóstico;
- predicción;
- optimización.

Responde:

¿Por qué ocurrió?

¿Qué ocurrirá?

¿Qué deberíamos hacer?

Puede sintetizarse:

BI → Comprensión
BA → Predicción y recomendación

En la práctica, ambos enfoques suelen integrarse.

4. Arquitectura de Business Intelligence

Una arquitectura básica de BI puede representarse:

Fuentes de datos



ETL/ELT



Data Warehouse



Modelo analítico



Dashboard



Usuario

Cada componente cumple una función específica.

5. Fuentes de datos

Los sistemas BI pueden utilizar información procedente de:

- ERP;
- CRM;
- SCM;
- archivos Excel;

- bases SQL;
- comercio electrónico;
- redes sociales;
- sensores;
- APIs;
- sistemas contables.

Por ejemplo:

Ventas + Clientes + Inventario + Finanzas

pueden integrarse en una sola plataforma.

Esto permite analizar la organización de forma transversal.

6. Procesos ETL

ETL significa:

Extract → Transform → Load

En español:

Extraer → Transformar → Cargar

Extraer

Recuperar información de diferentes fuentes.

Transformar

Limpiar, homologar y preparar datos.

Cargar

Ingresa la información en el repositorio analítico.

Por ejemplo:

"Babahoyo"
"BABAHOYO"
"babahoyo"

deberían estandarizarse antes del análisis.

7. ELT

En arquitecturas modernas también se utiliza:

Extract → Load → Transform

En ELT, los datos se cargan primero y posteriormente se transforman dentro del repositorio.

Esta alternativa suele utilizarse en plataformas cloud capaces de procesar grandes volúmenes de información.

8. Data Warehouse

El **data warehouse** constituye un repositorio orientado al análisis.

Sus características principales incluyen:

- integración;
- almacenamiento histórico;
- consistencia;
- orientación temática;
- soporte para consultas.

Por ejemplo, puede conservar ventas de varios años:

2022
2023
2024
2025
2026

Esto permite analizar tendencias y comparar períodos.

9. Modelado dimensional

Una estructura ampliamente utilizada en BI es el esquema estrella.

En el centro se encuentra una tabla de hechos.

Por ejemplo:

Hechos Ventas

- cantidad;
- ingreso;
- costo;
- descuento.

Alrededor se ubican dimensiones:

Tiempo
Cliente

Producto
Sucursal
Vendedor

Esto puede representarse como:

Dimensiones → *Hechos* ← *Dimensiones*

El diseño facilita consultas empresariales.

10. Tabla de hechos

Una tabla de hechos contiene medidas cuantitativas.

Ejemplo:

Fecha	Producto	Cliente	Cantidad	Venta
01/06	A	001	5	250
01/06	B	002	3	180

Las medidas pueden agregarse mediante:

SUM
AVG
COUNT
MIN
MAX

11. Tablas de dimensiones

Las dimensiones describen los hechos.

Ejemplo:

Dimensión Producto

ID Producto Categoría

Dimensión Cliente

ID Cliente Ciudad

Dimensión Tiempo

Fecha Mes Trimestre Año

Estas tablas permiten analizar la información desde diferentes perspectivas.

12. OLAP

El procesamiento analítico en línea, **OLAP**, permite explorar información multidimensional.

Por ejemplo:

Ventas

pueden analizarse por:

Tiempo × Producto × Región

Un gerente puede observar:

ventas anuales;

luego:

ventas trimestrales;

posteriormente:

ventas mensuales;

y finalmente:

ventas diarias.

Este proceso se denomina **drill-down**.

13. Operaciones OLAP

Entre las principales se encuentran:

Drill-down

Ir hacia mayor detalle.

Año → Mes → Día

Roll-up

Resumir información.

Día → Mes → Año

Slice

Seleccionar una dimensión.

Dice

Seleccionar varias dimensiones.

Estas operaciones permiten explorar datos dinámicamente.

14. Dashboards

Los dashboards constituyen uno de los productos más visibles de BI.

Su objetivo consiste en presentar indicadores de forma clara.

Por ejemplo:

KPI	Resultado	Meta
Ventas	\$750.000	\$800.000
Margen	18 %	20 %
Clientes nuevos	420	500
Retención	90 %	92 %
Devoluciones	2,3 %	<2 %

El dashboard facilita identificar rápidamente:

Resultado → Desviación → Acción

15. Diseño de dashboards

Un dashboard efectivo debe ser:

- claro;
- simple;
- relevante;
- visualmente ordenado;
- actualizado;
- orientado a decisiones.

Debe evitar:

- exceso de gráficos;
- indicadores irrelevantes;
- colores innecesarios;
- información duplicada;
- sobrecarga visual.

La regla principal es:

Menos información + Mayor relevancia = Mejor dashboard

16. KPI en Business Intelligence

Los KPI permiten monitorear objetivos empresariales.

Algunos ejemplos:

Ventas

$$\text{Cumplimiento} = \frac{\text{Ventas reales}}{\text{Meta}} \times 100$$

Rentabilidad

$$\text{Margen} = \frac{\text{Utilidad}}{\text{Ventas}} \times 100$$

Retención

$$\text{Retención} = \frac{\text{Clientes retenidos}}{\text{Clientes iniciales}} \times 100$$

Productividad

$$\text{Productividad} = \frac{\text{Output}}{\text{Input}}$$

BI permite automatizar estos cálculos.

17. Cuadro de mando integral

La inteligencia de negocios puede integrarse con el **Balanced Scorecard**.

Este enfoque considera cuatro perspectivas:

Financiera

- rentabilidad;
- ingresos;
- costos.

Clientes

- satisfacción;
- retención;
- participación.

Procesos internos

- productividad;

- calidad;
- eficiencia.

Aprendizaje y crecimiento

- capacitación;
- innovación;
- competencias.

Un sistema BI puede vincular indicadores de todas estas perspectivas.

18. Business Intelligence en ventas

En ventas puede utilizarse para:

- analizar vendedores;
- monitorear metas;
- detectar tendencias;
- comparar territorios;
- analizar productos.

Ejemplo:

Vendedor	Ventas	Meta	Cumplimiento
A	120.000	100.000	120 %
B	85.000	100.000	85 %
C	97.000	100.000	97 %

El gerente puede identificar rápidamente brechas de desempeño.

19. BI en marketing

En marketing permite monitorear:

- conversiones;
- campañas;
- canales;
- leads;
- clientes;
- costo de adquisición.

Por ejemplo:

$$CAC = \frac{\text{Costo de adquisición}}{\text{Clientes nuevos}}$$

Si:

$$\text{Costo} = 10000$$

y:

$$\text{Clientes} = 200$$

entonces:

$$CAC = 50$$

La empresa invierte \$50 por cada nuevo cliente.

20. BI en finanzas

La inteligencia de negocios permite analizar:

- ingresos;
- gastos;
- márgenes;
- liquidez;
- cartera;
- flujo de caja.

Puede utilizar dashboards para comparar:

Real

vs.

Presupuesto

Por ejemplo:

$$\text{Variación} = \text{Real} - \text{Presupuesto}$$

Esto facilita el control financiero.

21. BI en operaciones

En operaciones pueden monitorearse:

- producción;
- capacidad;
- inventarios;
- tiempos;
- calidad;
- mantenimiento.

Ejemplo:

$$Utilización = \frac{Producción\ real}{Capacidad} \times 100$$

Un dashboard operacional puede actualizarse en tiempo real.

22. BI en recursos humanos

Puede utilizarse para:

- rotación;
- ausentismo;
- capacitación;
- desempeño;
- productividad.

Por ejemplo:

$$Rotación = \frac{Salidas}{Promedio\ empleados} \times 100$$

Al integrar datos históricos, es posible identificar áreas con mayor rotación.

23. Self-Service BI

El **self-service BI** permite que usuarios de negocio generen sus propios análisis sin depender constantemente del área de tecnología.

Herramientas como:

- Power BI;
- Tableau;

- Qlik;

facilitan:

- conexión de datos;
- visualización;
- filtrado;
- creación de indicadores.

Esto democratiza el acceso a la información.

Sin embargo, requiere normas de gobierno para evitar múltiples versiones de un mismo indicador.

24. Power BI

Power BI es una de las herramientas ampliamente utilizadas en entornos empresariales.

Permite:

- conectar datos;
- transformar información;
- crear modelos;
- generar dashboards;
- compartir informes.

Un flujo puede representarse:

Excel/ERP/CRM



Power Query



Modelo



DAX



Dashboard

25. Indicadores mediante DAX

DAX permite construir medidas.

Por ejemplo:

$$Ventas\ Totales = SUM(Ventas[Monto])$$

Una medida de margen:

$$Margen\% = \frac{Utilidad}{Ventas}$$

También pueden construirse análisis temporales como:

- ventas acumuladas;
- crecimiento interanual;
- comparación mensual.

26. BI en tiempo real

Tradicionalmente, BI analizaba información histórica.

Actualmente pueden desarrollarse dashboards casi en tiempo real.

Por ejemplo:

Sensor



Streaming



BI



Alerta

Esto permite monitorear:

- producción;
- logística;
- ventas digitales;
- transacciones;
- fraudes.

27. Integración con inteligencia artificial

La BI contemporánea se encuentra cada vez más integrada con inteligencia artificial.

Puede incorporarse:

- lenguaje natural;
- generación automática de informes;
- detección de anomalías;
- predicciones;
- recomendaciones.

Por ejemplo:

“Muéstreme los productos con mayor caída de ventas durante los últimos tres meses”.

Un sistema inteligente puede traducir la pregunta a una consulta analítica.

28. Analítica aumentada

La analítica aumentada utiliza IA para automatizar partes del proceso de análisis.

Puede incluir:

- limpieza automática;
- detección de tendencias;
- generación de explicaciones;
- recomendación de visualizaciones.

El proceso evoluciona desde:

Usuario consulta

hacia:

Sistema detecta

Por ejemplo, el sistema podría generar una alerta:

“Las ventas de la categoría X disminuyeron 18 % respecto al promedio trimestral”.

29. Calidad de datos

Un sistema BI depende de datos confiables.

Los problemas más frecuentes incluyen:

- duplicados;

- valores faltantes;
- errores de captura;
- inconsistencias;
- formatos diferentes.

Puede expresarse:

$$BI \text{ de calidad} \leq \text{Datos de calidad}$$

Si los datos son incorrectos, el dashboard también lo será.

30. Gobierno de datos

El gobierno de datos establece responsabilidades y reglas.

Debe definir:

- propietarios de datos;
- acceso;
- seguridad;
- estándares;
- calidad;
- almacenamiento.

Por ejemplo, una organización debe establecer cuál es el valor oficial de:

Ventas netas

Si diferentes departamentos calculan este indicador de manera distinta, se producirán inconsistencias.

31. Seguridad en BI

Los sistemas BI manejan información estratégica.

Entre los riesgos se encuentran:

- acceso no autorizado;
- filtración;
- manipulación;
- pérdida.

Por ello deben implementarse:

- roles;

- autenticación;
- permisos;
- auditoría;
- cifrado.

Un vendedor podría acceder únicamente a su región, mientras que la gerencia accede a toda la organización.

32. Caso aplicado

Considérese una empresa comercial con tres sucursales.

Dispone de:

- ventas en Excel;
- clientes en CRM;
- inventarios en ERP;
- gastos en sistema contable.

La información se encuentra separada.

La gerencia recibe reportes con 15 días de retraso.

33. Propuesta BI

Se propone:

ERP + CRM + Excel + Contabilidad



ETL



Data Warehouse



Power BI



Dashboard

Los principales indicadores serían:

- ventas;
- margen;
- inventarios;
- clientes;
- gastos;
- rentabilidad.

34. Dashboard ejecutivo propuesto

Indicador	Valor
Ventas	\$1.250.000
Margen	17,8 %
Clientes activos	8.500
Inventario	\$280.000
Rotación	6,4
Devoluciones	2,1 %
Cumplimiento meta	94 %

Además, podrían utilizarse filtros por:

- sucursal;
- vendedor;
- categoría;
- mes.

35. Análisis del dashboard

Supóngase que se identifica:

$$\text{Ventas Sucursal B} = -12\%$$

La gerencia puede profundizar:

Sucursal



Categoría

↓
Producto

↓
Vendedor

y descubrir que una categoría específica explica la mayor parte de la reducción.
Esto transforma un simple indicador en diagnóstico.

36. Integración con modelos predictivos

El sistema BI puede incorporar resultados predictivos.

Por ejemplo:

Ventas reales

junto con:

Ventas pronosticadas

Un dashboard podría mostrar:

Mes	Real	Predicción
Julio	120.000	118.000
Agosto	128.000	130.000
Septiembre	—	135.000

Así se conecta BI con analítica predictiva.

37. Madurez en Business Intelligence

Puede establecerse una escala de madurez:

Nivel 1

Reportes manuales.

Nivel 2

Dashboards básicos.

Nivel 3

Integración de datos.

Nivel 4

Self-service BI.

Nivel 5

Analítica predictiva.

Nivel 6

IA integrada.

Puede representarse:

Manual → Visual → Integrado → Analítico → Predictivo → Inteligente

38. Beneficios de BI

Entre los beneficios se encuentran:

- acceso rápido a información;
- reducción del tiempo de reporte;
- mejor control;
- integración;
- transparencia;
- identificación de tendencias;
- monitoreo de KPI;
- mejor toma de decisiones.

Puede expresarse:

Valor BI = Información correcta + Momento correcto + Usuario correcto

39. Limitaciones

La BI puede presentar problemas relacionados con:

- inversión;
- capacitación;
- calidad de datos;
- integración;
- resistencia al cambio;
- seguridad;
- exceso de indicadores.

Un dashboard con 100 indicadores puede ser menos útil que uno con 10 indicadores estratégicos.

Por ello:

Más información ≠ Mejor decisión

40. Factores críticos de éxito

Una implementación exitosa requiere:

- apoyo directivo;
- objetivos definidos;
- datos confiables;
- infraestructura adecuada;
- capacitación;
- gobierno;
- cultura analítica.

La BI debe responder a preguntas empresariales concretas.

En lugar de preguntar:

¿Qué gráficos podemos crear?

debería preguntarse:


¿Qué decisiones necesitamos mejorar?

41. Tendencias de la inteligencia de negocios

Las principales tendencias incluyen:

- cloud BI;
- inteligencia artificial;
- analítica aumentada;
- lenguaje natural;
- BI móvil;
- datos en tiempo real;
- automatización;
- integración con aprendizaje automático.

La evolución puede representarse:



42. Relación con capítulos anteriores

La inteligencia de negocios integra varios conceptos desarrollados previamente.

Capítulo 1

Analítica empresarial.

Capítulo 2

Estadística.

Capítulo 3

Sistemas de información.


Capítulo 4

Minería de datos.

Capítulo 5

Modelos predictivos.

La BI funciona como una plataforma de integración:



43. Conclusiones

La inteligencia de negocios constituye una herramienta fundamental para transformar datos empresariales en información relevante para la gestión.

Su funcionamiento depende de una arquitectura compuesta por fuentes de datos, procesos ETL o ELT, repositorios analíticos, modelos de datos, indicadores y herramientas de visualización.

Los dashboards permiten monitorear el desempeño de ventas, finanzas, marketing, operaciones y recursos humanos, mientras que los sistemas actuales incorporan progresivamente inteligencia artificial y analítica predictiva.

Sin embargo, el éxito de BI no depende únicamente de disponer de software moderno. También requiere calidad de datos, objetivos claramente definidos, gobierno de información y una cultura orientada al análisis.

La inteligencia de negocios puede sintetizarse mediante:

Datos → Integración → Indicadores → Análisis → Decisión

En organizaciones con mayor madurez analítica, este proceso evoluciona hacia:

BI + Machine Learning + IA → Decisiones inteligentes

De esta manera, la inteligencia de negocios se convierte en un componente estratégico para mejorar la velocidad, precisión y calidad de las decisiones empresariales.

Referencias bibliográficas

Few, S. (2013). *Information dashboard design: Displaying data for at-a-glance monitoring* (2nd ed.). Analytics Press.

Kimball, R., & Ross, M. (2013). *The data warehouse toolkit: The definitive guide to dimensional modeling* (3rd ed.). Wiley.

Laudon, K. C., Laudon, J. P., & Traver, C. G. (2025). *Management information systems: Managing the digital firm* (18th ed.). Pearson.

Sharda, R., Delen, D., & Turban, E. (2024). *Business intelligence, analytics, data science, and AI* (5th ed.). Pearson.

Shmueli, G., Bruce, P. C., Gedeck, P., & Patel, N. R. (2023). *Data mining for business analytics: Concepts, techniques, and applications in Python*. Wiley.

Turban, E., Pollard, C., & Wood, G. (2021). *Information technology for management: Driving digital transformation to increase local and global performance, growth and sustainability* (12th ed.). Wiley.

CAPÍTULO 7

Gestión ambiental y ciencia de datos

Gabriela Alexandra Castro López

gcastrol@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0000-0001-9953-5491>

1. Introducción

La gestión ambiental empresarial ha evolucionado desde un enfoque centrado únicamente en el cumplimiento normativo hacia una perspectiva estratégica basada en prevención, eficiencia, sostenibilidad y uso intensivo de información. En este contexto, la ciencia de datos ofrece herramientas capaces de apoyar el monitoreo ambiental, la identificación de riesgos, el análisis de tendencias y la evaluación del desempeño sostenible.

Las organizaciones generan actualmente grandes volúmenes de información relacionada con:

- consumo energético;
- uso de agua;
- emisiones;
- generación de residuos;
- transporte;
- procesos productivos;
- calidad ambiental;
- mantenimiento;
- proveedores;
- cumplimiento normativo.

Cuando estos datos son integrados y analizados adecuadamente, pueden convertirse en conocimiento útil para reducir impactos y mejorar decisiones.

El proceso puede representarse como:

Datos ambientales → Análisis → Indicadores → Predicción → Decisión → Mejora

La relación entre gestión ambiental y ciencia de datos resulta especialmente relevante en el marco de los sistemas de gestión ambiental, los criterios ESG, la economía circular y los nuevos estándares de divulgación de sostenibilidad.

2. Concepto de gestión ambiental empresarial

La gestión ambiental comprende el conjunto de políticas, procedimientos, recursos y acciones destinadas a controlar y reducir los impactos ambientales producidos por las actividades de una organización.

Puede expresarse como:

$$Gestión\ ambiental = Prevención + Control + Evaluación + Mejora$$

Su finalidad no consiste únicamente en cumplir requisitos legales, sino también en:

- utilizar eficientemente recursos;
- reducir residuos;
- disminuir emisiones;
- prevenir contaminación;
- mejorar desempeño ambiental;
- fortalecer reputación;
- reducir riesgos.

La gestión ambiental moderna se integra progresivamente con la estrategia empresarial.

3. Sistemas de gestión ambiental

Uno de los principales marcos internacionales corresponde a **ISO 14001**.

Un sistema de gestión ambiental permite organizar:

- política ambiental;
- identificación de aspectos;
- evaluación de impactos;
- objetivos;
- controles operacionales;
- seguimiento;
- auditoría;
- mejora.

Su lógica responde al ciclo:

$$Planificar \rightarrow Hacer \rightarrow Verificar \rightarrow Actuar$$

Este enfoque facilita que los datos ambientales formen parte permanente de la gestión.

4. Aspectos e impactos ambientales

Un aspecto ambiental representa un elemento de las actividades de una organización que puede interactuar con el ambiente.

Ejemplos:

- consumo de electricidad;
- uso de agua;
- combustibles;
- residuos;
- emisiones.

El impacto corresponde al cambio producido.

Por ejemplo:

Consumo de combustible → Emisiones de CO₂
Uso de agua → Presión sobre recursos hídricos

La ciencia de datos puede ayudar a identificar qué aspectos generan mayor impacto.

5. Indicadores ambientales

La medición requiere indicadores cuantitativos.

Algunos ejemplos:

Consumo energético

$$CE = \frac{\text{Energía consumida}}{\text{Unidad producida}}$$

Consumo de agua

$$CA = \frac{\text{Agua utilizada}}{\text{Unidad producida}}$$

Generación de residuos

$$GR = \frac{\text{Residuos generados}}{\text{Producción}}$$

Reciclaje

$$TR = \frac{\text{Residuos reciclados}}{\text{Residuos totales}} \times 100$$

Estos indicadores permiten comparar períodos y detectar desviaciones.

6. Huella de carbono

La huella de carbono representa las emisiones de gases de efecto invernadero asociadas a una actividad.

Puede expresarse en:

$$CO_2e$$

Una fórmula simplificada es:

$$Emisiones = Actividad \times Factor \text{ de emisión}$$

Por ejemplo:

$$Litros \text{ de combustible} \times Factor$$

La información puede organizarse por:

- procesos;
- vehículos;
- sucursales;
- productos;
- proveedores.

Esto facilita identificar fuentes prioritarias de reducción.

7. ESG

El enfoque **ESG** integra tres dimensiones:

$$\begin{aligned} E &= Environmental \\ S &= Social \\ G &= Governance \end{aligned}$$

La dimensión ambiental incluye aspectos como:

- emisiones;
- energía;
- residuos;
- biodiversidad;
- agua;
- cambio climático.

Los datos ambientales adquieren importancia porque permiten convertir compromisos generales en indicadores verificables.

8. IFRS S1 e IFRS S2

Los estándares internacionales de sostenibilidad han reforzado la importancia de información ambiental confiable.

IFRS S1 establece requerimientos generales de divulgación de información financiera relacionada con sostenibilidad.

IFRS S2 se enfoca específicamente en riesgos y oportunidades relacionados con el clima.

Esto implica que las organizaciones requieren sistemas capaces de recopilar información de:

Riesgos + Emisiones + Escenarios + Metas + Indicadores

La gestión ambiental se conecta así con la información financiera y estratégica.

9. Ciencia de datos ambiental

La ciencia de datos integra:

- estadística;
- programación;
- machine learning;
- visualización;
- conocimiento del dominio.

Aplicada al ambiente, puede utilizarse para:

- detectar patrones;
- estimar consumo;
- identificar anomalías;
- predecir riesgos;
- clasificar eventos;
- optimizar recursos.

Puede expresarse:

Ciencia de datos ambiental = Datos + Modelos + Conocimiento ambiental

10. Fuentes de datos ambientales

Las principales fuentes incluyen:

- medidores;
- sensores;

- registros de producción;
- facturas energéticas;
- estaciones meteorológicas;
- GPS;
- imágenes satelitales;
- sistemas ERP;
- reportes ambientales.

Por ejemplo:

Sensores + ERP + Meteorología

pueden integrarse para analizar el consumo energético de una planta.

11. Internet de las cosas

El IoT permite capturar datos ambientales continuamente.

Ejemplos:

- temperatura;
- humedad;
- ruido;
- calidad del aire;
- consumo eléctrico;
- nivel de agua.

El flujo puede representarse como:

Sensor → Red → Base de datos → Dashboard

Esto permite monitoreo casi en tiempo real.

12. Calidad del aire

Los sensores pueden registrar:

- partículas;
- dióxido de carbono;
- monóxido de carbono;
- temperatura;

- humedad.

Los datos pueden analizarse mediante series temporales.

Por ejemplo:

$$PM_{2.5,t}$$

puede compararse por hora, día o zona.

La analítica permite detectar:

Picos
Tendencias
Anomalías

13. Analítica del consumo energético

Una empresa puede modelar:

$$\text{Consumo} = f(P, r, o, \text{ducciónTemperaturaHorarioEquipos})$$

Por ejemplo, si aumenta el consumo sin incremento de producción, podría existir una ineficiencia.

Puede calcularse:

$$\text{Intensidad energética} = \frac{kWh}{\text{Unidad producida}}$$

Una reducción sostenida indicaría mejora.

14. Predicción del consumo energético

Los modelos predictivos permiten estimar necesidades futuras.

Por ejemplo:

$$E_{t+1} = f(E_t, P, r, \text{ducciónTemperaturaHorario})$$

Esto puede apoyar:

- presupuestos;
- planificación;
- compra de energía;
- mantenimiento.

Los modelos pueden incluir regresión, árboles, Random Forest o redes neuronales.

15. Gestión del agua

La analítica puede aplicarse a:

- consumo;
- fugas;
- calidad;
- presión;
- reutilización.

Por ejemplo:

$$\text{Consumo específico} = \frac{m^3 \text{ de agua}}{\text{Unidad producida}}$$

Si el indicador aumenta sin cambios en producción, puede investigarse una posible fuga o pérdida.

16. Detección de anomalías

Una anomalía corresponde a un comportamiento diferente del patrón esperado.

Por ejemplo:

$$\text{Consumo}_{actual} \gg \text{Consumo}_{promedio}$$

Puede establecerse una regla:

$$|X - \mu| > 3\sigma$$

para identificar observaciones inusuales.

También pueden utilizarse algoritmos de machine learning.

17. Gestión de residuos

Los datos pueden clasificarse según:

- tipo;
- origen;
- cantidad;
- peligrosidad;
- tratamiento;
- destino.

Por ejemplo:

Residuo	Cantidad	Tratamiento
Cartón	500 kg	Reciclaje
Plástico	250 kg	Reciclaje
Orgánico	700 kg	Compostaje

Esto permite medir:

$$Tasa\ de\ aprovechamiento = \frac{Residuos\ recuperados}{Residuos\ generados} \times 100$$

18. Economía circular

La economía circular busca reducir la extracción de recursos y mantener materiales en uso durante mayor tiempo.

Puede representarse:

$$Extraer \rightarrow Producir \rightarrow Usar \rightarrow Desechar$$

como modelo lineal.

Frente a:

$$Reducir \rightarrow Reutilizar \rightarrow Reparar \rightarrow Reciclar$$

La ciencia de datos permite medir flujos de materiales y detectar oportunidades de recuperación.

19. Analítica de residuos

Puede construirse un modelo:

$$Residuos = f(Producción, Producto, Turno, Proceso)$$

Esto permite determinar qué factores explican mayor generación.

Un árbol de decisión podría identificar:

determinados productos o turnos presentan mayor tasa de desperdicio.

Esto facilita acciones focalizadas.

20. Machine learning y ambiente

Los modelos de aprendizaje automático pueden utilizarse para:

- predicción de emisiones;

- detección de contaminación;
- clasificación de residuos;
- predicción energética;
- mantenimiento;
- análisis climático.

La lógica general es:

$$\text{Datos} \rightarrow \text{Entrenamiento} \rightarrow \text{Modelo} \rightarrow \text{Predicción}$$

21. Mantenimiento predictivo y sostenibilidad

El mantenimiento predictivo también tiene implicaciones ambientales.

Una máquina ineficiente puede consumir:

Más energía

y generar:

Más emisiones

Los sensores pueden registrar:

- vibración;
- temperatura;
- presión;
- consumo.

Un modelo puede estimar:

$$P(\text{Falla}) = f(\text{Vibración}, \text{Temperatura}, \text{Consumo})$$

Esto permite intervenir antes del fallo.

22. Teledetección

La teledetección utiliza información obtenida mediante:

- satélites;
- drones;
- sensores remotos.

Puede aplicarse a:

- vegetación;
- uso del suelo;
- contaminación;
- deforestación;
- cuerpos de agua.

Los datos satelitales permiten analizar extensiones territoriales que serían costosas de monitorear mediante métodos exclusivamente presenciales.

23. Sistemas de información geográfica

Los **GIS** permiten integrar información con ubicación espacial.

Por ejemplo:

$$\textit{Contaminación} + \textit{Coordenadas}$$

puede generar mapas de:

- riesgo;
- emisiones;
- residuos;
- puntos críticos.

En una ciudad podrían identificarse sectores con mayor concentración de contaminantes.

24. Analítica climática

Las empresas también deben considerar variables climáticas.

Ejemplos:

- temperatura;
- precipitaciones;
- inundaciones;
- sequías;
- eventos extremos.

Un modelo podría estimar:

$$\textit{Riesgo operativo} = f\left(\textit{Precipitación}, \textit{Ubicación}, \textit{Infraestructura}\right)$$

Esto facilita planificación de contingencias.

25. Riesgo ambiental

Puede representarse:

$$\text{Riesgo} = \text{Probabilidad} \times \text{Impacto}$$

Por ejemplo:

Evento	Probabilidad	Impacto	Riesgo
Derrame	3	5	15
Fuga	2	4	8
Incendio	2	5	10

Los datos históricos pueden mejorar la estimación de probabilidades.

26. Modelos predictivos de riesgo

Un modelo puede estimar:

$$P(\text{Evento ambiental}) = f(\text{Equipo}, \text{Temperatura}, \text{Presión}, \text{Historial})$$

Por ejemplo:

$$P(\text{Derrame}) = 0.78$$

podría activar:

$$\text{Inspección} + \text{Mantenimiento} + \text{Prevención}$$

Esto representa una evolución desde una gestión reactiva hacia una gestión preventiva.

27. Dashboards ambientales

Los indicadores pueden integrarse en un dashboard.

Ejemplo:

Indicador	Actual	Meta
Energía	120 kWh/unidad	110
Agua	4,2 m³/unidad	4,0
Residuos reciclados	72 %	80 %
Emisiones	950 t CO ₂ e	900
Incidentes	2	0

El dashboard facilita el seguimiento de metas ambientales.

28. Semáforos de desempeño

Puede establecerse:

Verde = Meta cumplida

Amarillo = Desviación moderada

Rojo = Desviación crítica

La visualización permite concentrar la atención gerencial en los puntos críticos.

29. Integración ambiental con BI

La información ambiental puede incorporarse a la inteligencia de negocios.

Por ejemplo:

ERP + Sensores + Datos ambientales



Data Warehouse



Power BI



Dashboard ESG

Esto evita que la gestión ambiental funcione como un sistema aislado.

30. Indicadores ambientales y financieros

Un aspecto importante consiste en relacionar desempeño ambiental y económico.

Por ejemplo:

$$\text{Costo energético} = \text{Consumo} \times \text{Tarifa}$$

Si una empresa reduce:

$$\text{Consumo} = 10\%$$

puede obtener simultáneamente:

$$\text{Menor impacto} + \text{Menor costo}$$

Esto demuestra que sostenibilidad y eficiencia económica pueden ser complementarias.

31. Caso aplicado

Considérese una empresa industrial con los siguientes datos mensuales:

Indicador	Valor
Producción	10.000 unidades
Energía	150.000 kWh
Agua	35.000 m ³
Residuos	12.000 kg
Reciclados	8.400 kg

Puede calcularse:

Intensidad energética

$$IE = \frac{150000}{10000}$$
$$IE = 15 \text{ kWh/unidad}$$

32. Intensidad hídrica

$$IH = \frac{35000}{10000}$$
$$IH = 3.5 \text{ m}^3/\text{unidad}$$

33. Tasa de reciclaje

$$TR = \frac{8400}{12000} \times 100$$
$$TR = 70\%$$

Estos indicadores permiten establecer una línea base.

34. Propuesta de mejora

Supóngase que la empresa establece:

$$IE_{meta} = 13.5$$
$$IH_{meta} = 3.2$$
$$TR_{meta} = 80\%$$

Los datos mensuales pueden utilizarse para monitorear avances y detectar desviaciones.

35. Modelo predictivo aplicado

La organización puede utilizar:

$$Energía = f(P, r, o, ducciónTurnosTemperaturaEquipo)$$

Si el modelo predice:

$$Consumo_{esperado} = 140000$$

pero el valor real es:

$$155000$$

se obtiene:


$$Desviación = 15000$$

Esto puede activar una investigación.

36. Uso de Orange

Orange puede utilizarse para proyectos ambientales sin programación avanzada.

Un flujo podría ser:



↓
Test and Score

↓
Predictions

Puede aplicarse para predecir:

- consumo;
- riesgo;
- categoría de residuos;
- eventos ambientales.

37. Beneficios empresariales

La integración entre ciencia de datos y gestión ambiental puede generar:

- reducción de costos;
- ahorro energético;
- reducción de residuos;
- prevención de incidentes;
- mejor cumplimiento;
- mejor reputación;
- mayor trazabilidad.

Puede resumirse:

Datos + Sostenibilidad = Mejores decisiones ambientales

38. Limitaciones

Entre las principales dificultades se encuentran:

- ausencia de datos;
- sensores defectuosos;
- baja calidad;
- costos de implementación;
- falta de personal especializado;
- información fragmentada.

Un modelo ambiental no puede compensar completamente datos deficientes.

Por ello:

$$\textit{Calidad de predicci3n} \leq \textit{Calidad del dato}$$

39. Ética y gobernanza de datos ambientales

Los datos deben administrarse con criterios de:

- trazabilidad;
- transparencia;
- integridad;
- verificabilidad.

Esto es especialmente importante cuando la informaci3n se utiliza para reportes p3blicos de sostenibilidad.

Manipular o seleccionar únicamente indicadores favorables puede conducir a prácticas de **greenwashing**.

Por ello:

$$\textit{Sostenibilidad real} \neq \textit{S3lo comunicaci3n}$$

Debe existir evidencia verificable.


40. Tendencias futuras

Entre las principales tendencias se encuentran:

- IA para sostenibilidad;
- sensores inteligentes;
- digital twins;
- analítica climática;
- predicci3n de emisiones;
- automatizaci3n ESG;
- monitoreo satelital;
- sistemas de alerta temprana.

La evoluci3n puede representarse:

$$\textit{Medici3n}$$




41. Integración con estrategia empresarial

La gestión ambiental debe alinearse con los objetivos estratégicos.

Por ejemplo:

Objetivo: Reducir emisiones 20%



La ciencia de datos permite convertir metas generales en procesos de seguimiento cuantificables.

42. Relación con capítulos anteriores

Los capítulos anteriores aportan herramientas fundamentales.

Sistemas de información

Permiten capturar datos ambientales.

Estadística

Permite describir y evaluar indicadores.

Minería de datos

Permite descubrir patrones.

Modelos predictivos

Permiten anticipar resultados.

Business Intelligence

Permite visualizar desempeño.

La gestión ambiental basada en datos integra todos estos elementos:

$$SI + Estadística + Data Mining + ML + BI$$



Gestión ambiental inteligente

43. Conclusiones

La gestión ambiental contemporánea requiere pasar de decisiones basadas únicamente en observaciones generales hacia procesos sustentados en información cuantitativa y verificable.

La ciencia de datos ofrece herramientas para analizar consumos, emisiones, residuos, riesgos y comportamiento ambiental. La integración de sensores, sistemas de información, modelos predictivos y plataformas de Business Intelligence permite incrementar la capacidad de monitoreo y anticipación.

Indicadores como intensidad energética, consumo hídrico, tasa de reciclaje y emisiones permiten evaluar objetivamente el desempeño. A su vez, algoritmos de aprendizaje automático pueden detectar anomalías, anticipar fallas y estimar riesgos.

La relación puede sintetizarse como:

Datos ambientales → Indicadores → Analítica → Predicción → Acción → Sostenibilidad

El desafío no consiste únicamente en disponer de tecnología, sino en integrar la información ambiental con los procesos empresariales y estratégicos.

De esta manera, la ciencia de datos puede contribuir simultáneamente a:

Eficiencia + Reducción de impactos + Cumplimiento + Competitividad

convirtiéndose en una herramienta relevante para avanzar hacia organizaciones más sostenibles.

Referencias bibliográficas

International Organization for Standardization. (2015). *ISO 14001:2015 environmental management systems—Requirements with guidance for use*. ISO.

IFRS Foundation. (2023a). *IFRS S1 general requirements for disclosure of sustainability-related financial information*. International Sustainability Standards Board.

IFRS Foundation. (2023b). *IFRS S2 climate-related disclosures*. International Sustainability Standards Board.

Sharda, R., Delen, D., & Turban, E. (2024). *Business intelligence, analytics, data science, and AI* (5th ed.). Pearson.

United Nations Environment Programme. (2024). *Emissions gap report 2024*. UNEP.

World Meteorological Organization. (2024). *State of the global climate 2023*. WMO.

CAPÍTULO 8

Analítica comercial y de marketing

Geovanny Washington Menoscal Verdezoto

gmenoscalv@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0009-0003-0990-1964>

Eva Jamilexi Salazar Yance

esalazary521@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0000-0002-5980-6776>

1. Introducción

La analítica comercial y de marketing permite utilizar datos para comprender mejor a los clientes, evaluar el desempeño de las acciones comerciales y mejorar la asignación de recursos. En un entorno caracterizado por consumidores digitales, múltiples canales de contacto y altos niveles de competencia, las organizaciones necesitan avanzar desde decisiones basadas en intuición hacia decisiones sustentadas en evidencia.

La analítica de marketing integra información proveniente de:

- ventas;
- CRM;
- campañas;
- redes sociales;
- comercio electrónico;
- sitios web;
- programas de fidelización;
- atención al cliente.

Su objetivo consiste en transformar estos datos en conocimiento útil para responder preguntas como:

¿Qué clientes generan mayor valor?

¿Qué campaña produce mejores resultados?

¿Qué canal convierte más?

¿Qué segmentos presentan mayor riesgo de abandono?

¿Qué producto debería ofrecerse a cada cliente?

El proceso puede representarse como:

Datos comerciales → Analítica → Segmentación → Predicción → Acción → Resultado

2. Concepto de analítica comercial

La analítica comercial comprende el uso sistemático de datos, métricas y modelos para mejorar decisiones relacionadas con ventas, clientes, productos y mercados.

Puede expresarse como:

Analítica comercial = Datos + Métodos + Interpretación + Decisión

No se limita a describir ventas históricas. También puede utilizarse para:

- estimar demanda;
- calcular rentabilidad;
- analizar clientes;
- evaluar vendedores;
- optimizar precios;
- pronosticar ventas.

3. Analítica de marketing

La analítica de marketing se enfoca específicamente en medir y optimizar actividades destinadas a atraer, convertir y retener clientes.

Entre sus aplicaciones se encuentran:

- segmentación;
- análisis de campañas;
- atribución;
- embudos;
- customer journey;
- retención;
- fidelización;
- personalización.

Puede representarse:

Marketing + Datos → Decisiones más precisas

La utilidad de la analítica depende de que los indicadores estén relacionados con objetivos empresariales reales.

4. Fuentes de datos de marketing

Una organización puede integrar:

CRM
ERP
Google Analytics
Redes sociales
E – commerce
Call center
Encuestas

Cada fuente aporta una perspectiva diferente del cliente.

El reto consiste en construir una visión integrada:

Cliente 360°

5. Customer 360

El enfoque Customer 360 busca reunir información de cada cliente en un perfil único.

Puede incluir:

- datos personales;
- historial de compras;
- frecuencia;
- valor monetario;
- reclamos;
- campañas recibidas;
- canales utilizados;
- comportamiento web.

Esto permite avanzar desde:

Cliente anonimo

hacia:

Cliente conocido

y posteriormente:

6. Segmentación de mercado

La segmentación consiste en dividir el mercado en grupos relativamente homogéneos.

Puede realizarse mediante variables:

Demográficas

- edad;
- ingreso;
- ocupación.

Geográficas

- ciudad;
- región;
- zona.

Psicográficas

- intereses;
- estilo de vida.

Conductuales

- frecuencia;
- recencia;
- uso;
- fidelidad.

La analítica moderna combina diferentes dimensiones.

7. Segmentación basada en comportamiento

Una segmentación conductual puede utilizar:

$$\text{Segmento} = f(\text{Frecuencia}, \text{Recencia}, \text{Ticket}, \text{Producto})$$

Por ejemplo:

Segmento A

Clientes frecuentes y de alto valor.

Segmento B

Clientes nuevos.

Segmento C

Clientes ocasionales.

Segmento D

Clientes inactivos.

Cada grupo requiere estrategias diferentes.

8. Buyer Persona y datos

El Buyer Persona representa un perfil ideal de cliente.

Tradicionalmente puede construirse mediante:

- entrevistas;
- observación;
- encuestas.

La analítica permite complementarlo con evidencia real.

Por ejemplo:

$$\textit{Buyer Persona} = \textit{Datos demográficos} + \textit{Conducta} + \textit{Necesidades} + \textit{Preferencias}$$

Esto evita construir perfiles exclusivamente intuitivos.

9. Customer Journey

El customer journey representa el recorrido del cliente.

Puede incluir:

Descubrimiento



Consideración



Compra



Uso



Recompra



Recomendación

La analítica permite medir cada etapa.

10. Embudo de conversión

Un embudo puede representarse:

10.000 *visitantes*



2.000 *interesados*



500 *oportunidades*



100 *compradores*

La tasa de conversión general sería:

$$\begin{aligned} \text{Conversion} &= \frac{100}{10000} \times 100 \\ \text{Conversion} &= 1\% \end{aligned}$$

El análisis permite identificar dónde se pierden más clientes.

11. Tasa de conversión

Puede calcularse:

$$TC = \frac{\text{Conversiones}}{\text{Usuarios expuestos}} \times 100$$

Por ejemplo:

$$\begin{aligned} TC &= \frac{250}{5000} \times 100 \\ TC &= 5\% \end{aligned}$$

Esta métrica es fundamental en comercio electrónico y campañas digitales.

12. Costo de adquisición de clientes

El **Customer Acquisition Cost (CAC)** mide cuánto cuesta adquirir un nuevo cliente.

$$CAC = \frac{\text{Gasto en adquisición}}{\text{Clientes nuevos}}$$

Si una empresa invierte:

15000

y obtiene:

300

clientes:

$$CAC = 50$$

Esto significa que cada cliente nuevo costó \$50.

13. Customer Lifetime Value

El **Customer Lifetime Value (CLV)** estima el valor económico esperado de un cliente.

Una aproximación sencilla puede ser:

$$CLV = \text{Ticket promedio} \times \text{Frecuencia} \times \text{Duración} \times \text{Margen}$$

Por ejemplo:

$$\begin{aligned} &100 \times 5 \times 4 \times 0.30 \\ &CLV = 600 \end{aligned}$$

Si:

$$CLV > CAC$$

la relación puede considerarse económicamente favorable.

14. Relación CLV/CAC

Un indicador útil es:

$$Ratio = \frac{CLV}{CAC}$$

Si:

$$CLV = 600$$

y:

$$CAC = 100$$

entonces:

$$Ratio = 6$$

Esto significa que el valor esperado del cliente es seis veces el costo de adquisición.

15. Retención de clientes

La tasa de retención puede calcularse:

$$TR = \frac{Clientes\ finales - Nuevos}{Clientes\ iniciales} \times 100$$

Si una empresa inicia con 1.000 clientes, termina con 1.100 y obtuvo 200 nuevos:

$$TR = \frac{1100 - 200}{1000} \times 100$$

$$TR = 90\%$$

16. Churn

El abandono puede calcularse:

$$Churn = \frac{Clientes\ perdidos}{Clientes\ iniciales} \times 100$$

Si se pierden 100 de 1.000:

$$Churn = 10\%$$

La analítica predictiva puede estimar:

$$P(Churn)$$

para cada cliente.

17. Predicción de churn

Variables posibles:

- recencia;
- frecuencia;
- disminución de compras;
- quejas;
- antigüedad;
- satisfacción.

Puede modelarse:

$$P(\text{Churn}) = f(R, F, \text{Quejas}, \text{Antigüedad})$$

Si:

$$P(\text{Churn}) > 0.80$$

la empresa puede activar una campaña de retención.

18. Analítica de campañas

Las campañas pueden analizarse mediante:

- alcance;
- clics;
- conversiones;
- ingresos;
- costo.

Un indicador importante es:

$$ROI = \frac{\text{Beneficio} - \text{Costo}}{\text{Costo}} \times 100$$

Supóngase:

$$\begin{aligned}\text{Beneficio} &= 20000 \\ \text{Costo} &= 5000\end{aligned}$$

Entonces:

$$ROI = 300\%$$

19. ROAS

El **Return on Advertising Spend** mide ingresos generados por publicidad.

$$ROAS = \frac{\text{Ingresos atribuidos}}{\text{Gasto publicitario}}$$

Si:

$$\text{Ingresos} = 25000$$

y:

$$\text{Publicidad} = 5000$$

entonces:

$$ROAS = 5$$

Por cada dólar invertido se generan cinco dólares de ingresos.

20. CTR

El **Click Through Rate** mide la proporción de usuarios que hacen clic.

$$CTR = \frac{\text{Clicks}}{\text{Impresiones}} \times 100$$

Por ejemplo:

$$CTR = \frac{500}{20000} \times 100$$
$$CTR = 2.5\%$$

21. Analítica de canales

Una empresa puede comparar:

Canal	CAC	Conversión	Ventas
Redes sociales	\$40	4,5 %	\$60.000
Email	\$15	8,2 %	\$45.000
Búsqueda	\$55	6,0 %	\$80.000

No siempre el canal con mayores ventas es el más eficiente.

La decisión requiere analizar simultáneamente:

$$\text{Costo} + \text{Conversión} + \text{Valor}$$

22. Modelos de atribución

La atribución busca determinar qué canales contribuyeron a la conversión.

Ejemplo:

Instagram → Google → Email → Compra

¿A qué canal se atribuye la venta?

Algunos modelos son:

- primer contacto;
- último contacto;
- lineal;
- basado en posición;
- basado en datos.

Los modelos simples pueden sobrevalorar determinados canales.

23. A/B testing

Las pruebas A/B permiten comparar dos alternativas.

Por ejemplo:

Versión A

Botón azul.

Versión B

Botón verde.

Supóngase:

$$\begin{aligned} \text{Conversion}_A &= 4.2\% \\ \text{Conversion}_B &= 5.5\% \end{aligned}$$

La diferencia debe analizarse estadísticamente antes de concluir que B es superior.

24. Hipótesis en A/B testing

Puede plantearse:

$$\begin{aligned} H_0: p_A &= p_B \\ H_1: p_A &\neq p_B \end{aligned}$$

Si el resultado es estadísticamente significativo, puede existir evidencia de diferencia entre las versiones.

El experimento debe controlar:

- tamaño de muestra;
- asignación aleatoria;
- duración;
- sesgos.

25. Analítica de precios

El precio puede analizarse mediante relaciones entre:

Precio

y:

Demanda

La elasticidad precio se expresa:

$$E_p = \frac{\% \Delta Q}{\% \Delta P}$$

Si:

$$E_p = -2$$

un incremento del 1 % en precio se asocia aproximadamente con una reducción del 2 % en cantidad demandada, bajo las condiciones del modelo.

26. Pricing basado en datos

Los datos permiten analizar:

- sensibilidad al precio;
- competencia;
- costos;
- inventarios;
- demanda;
- estacionalidad.

Puede construirse:

$$\text{Precio óptimo} = f(\text{Demanda}, \text{Costo}, \text{Competencia}, \text{Margen})$$

Este enfoque puede mejorar rentabilidad.

27. Sistemas de recomendación

Los sistemas de recomendación buscan anticipar productos relevantes para cada cliente.

Ejemplo:

$$\text{Cliente } A \rightarrow \text{Producto } X$$

Las recomendaciones pueden basarse en:

- historial;
- similitud entre clientes;
- similitud entre productos;
- contenido.

Son frecuentes en comercio electrónico.

28. Cross-selling

La venta cruzada consiste en ofrecer productos complementarios.

Ejemplo:

$$\begin{aligned} \text{Celular} &\rightarrow \text{Protector} \\ \text{Impresora} &\rightarrow \text{Tinta} \end{aligned}$$

Las reglas de asociación pueden apoyar este análisis.

29. Up-selling

El up-selling busca ofrecer una alternativa superior.

Ejemplo:

$$\text{Plan estándar} \rightarrow \text{Plan premium}$$

La analítica puede identificar qué clientes presentan mayor probabilidad de aceptar la oferta.

30. Analítica de redes sociales

Las redes sociales generan información sobre:

- alcance;
- interacción;
- sentimiento;
- comentarios;
- tendencias.

Puede calcularse:

$$Engagement = \frac{Interacciones}{Alcance} \times 100$$

Sin embargo, un alto engagement no garantiza necesariamente ventas.

Por ello debe conectarse con indicadores comerciales.

31. Análisis de sentimiento

El análisis de sentimiento clasifica opiniones.

Por ejemplo:

Positivo
Neutral
Negativo

Puede aplicarse a:

- comentarios;
- encuestas;
- reseñas;
- redes sociales.

Esto permite identificar percepciones sobre productos y marcas.

32. Analítica omnicanal

Los consumidores pueden interactuar mediante:

- tienda física;
- web;
- aplicación;
- WhatsApp;
- redes;
- call center.

La analítica omnicanal busca integrar estos contactos.

Puede representarse:

$$Canal_1 + Canal_2 + \dots + Canal_n$$

↓

Perfil único

El objetivo es proporcionar una experiencia consistente.

33. Caso aplicado

Considérese una empresa de comercio electrónico con:

20.000 usuarios

Durante un mes obtiene:

Indicador	Resultado
Visitantes	20.000
Carritos	4.000
Compras	1.200
Ingresos	\$96.000
Publicidad	\$12.000
Clientes nuevos	800

34. Conversión

$$TC = \frac{1200}{20000} \times 100$$
$$TC = 6\%$$

35. Ticket promedio

$$Ticket = \frac{96000}{1200}$$
$$Ticket = \$80$$

36. CAC

$$CAC = \frac{12000}{800}$$

$$CAC = \$15$$

Estos indicadores ofrecen una visión básica del desempeño comercial.

37. Abandono de carrito

Si 4.000 usuarios agregaron productos y 1.200 compraron:

$$Abandono = \frac{4000 - 1200}{4000} \times 100$$

$$Abandono = 70\%$$

Esto identifica una oportunidad de mejora.

La empresa debería analizar:

- precio;
- costos de envío;
- proceso de pago;
- confianza;
- métodos de pago.

38. Modelo predictivo aplicado

La empresa puede estimar:

$$P(Compra) = f(Visitas, TiempoCarrito, Historial, Descuento)$$

Un usuario con:

$$P(Compra) = 0.85$$

podría recibir una comunicación personalizada.

Otro con:

$$P(Compra) = 0.20$$

podría requerir una estrategia diferente.

39. Dashboard comercial

Un dashboard podría incluir:

KPI	Resultado
Ventas	\$96.000
Conversión	6 %
CAC	\$15
Ticket	\$80
Abandono carrito	70 %
Retención	88 %
ROAS	8

Esto permite monitorear simultáneamente adquisición, conversión y rentabilidad.

40. Uso de Business Intelligence

Herramientas como Power BI permiten conectar:

CRM + Ventas + Marketing + Web



Dashboard

Los análisis pueden filtrarse por:

- producto;
- campaña;
- cliente;
- canal;
- período;
- ubicación.

41. Uso de Orange

Orange puede utilizarse para analizar datos comerciales.

Un flujo posible es:

File



Select Columns



Rank



Logistic Regression
Random Forest
Neural Network



Test and Score



Predictions

Esto permite identificar clientes con mayor probabilidad de:

- compra;
- abandono;
- respuesta;
- conversión.

42. Inteligencia artificial generativa en marketing

La IA generativa puede apoyar:

- generación de contenidos;
- personalización;
- análisis de comentarios;
- resumen de campañas;
- interacción con clientes.

Sin embargo, su uso debe estar acompañado de:

- supervisión;
- privacidad;
- control de calidad;
- transparencia.

La automatización no elimina la responsabilidad de la organización.

43. Ética y privacidad

La analítica comercial utiliza información sobre personas.

Por ello deben considerarse:

- consentimiento;
- privacidad;
- protección de datos;
- transparencia;
- no discriminación.

Una predicción comercial puede ser precisa pero resultar inadecuada si utiliza datos obtenidos o tratados de forma poco ética.

Por tanto:

$$\textit{Analítica responsable} = \textit{Precisión} + \textit{Privacidad} + \textit{Transparencia} + \textit{Equidad}$$

44. Limitaciones de la analítica de marketing

Entre las principales limitaciones se encuentran:

- datos incompletos;
- atribución imperfecta;
- cambios del consumidor;
- sesgo de selección;
- indicadores de vanidad;
- problemas de integración.

Por ejemplo:

Likes

pueden aumentar sin que:

Ventas

aumenten.

Por ello, los indicadores digitales deben conectarse con resultados empresariales.

45. Indicadores de vanidad y KPI estratégicos

Un indicador de vanidad luce favorable pero puede tener poca relación con resultados.

Ejemplos:

- seguidores;
- impresiones;
- visualizaciones.

Pueden ser útiles, pero deben relacionarse con:

- conversiones;
- ingresos;
- retención;
- rentabilidad.

En consecuencia:

$$Métrica \neq KPI$$

Un KPI debe estar vinculado con un objetivo estratégico.

46. Beneficios empresariales

La analítica comercial puede contribuir a:

- mejorar segmentación;
- aumentar conversión;
- reducir CAC;
- elevar CLV;
- disminuir churn;
- optimizar campañas;
- mejorar precios;
- incrementar rentabilidad.

El valor se produce cuando:

$$Insight \rightarrow Acción$$

No basta con detectar un patrón si no se transforma en una decisión.

47. Tendencias actuales

Entre las tendencias se encuentran:

- personalización con IA;
- customer data platforms;
- marketing predictivo;
- automatización;
- analítica en tiempo real;
- atribución basada en datos;
- social listening;
- recomendadores;
- IA generativa.

La evolución puede representarse:

Marketing descriptivo



Marketing segmentado



Marketing predictivo



Marketing personalizado



Marketing inteligente

48. Relación con capítulos anteriores

La analítica comercial integra conceptos previamente desarrollados.

Minería de datos

Descubre patrones.

Modelos predictivos

Anticipan comportamientos.

BI

Visualiza indicadores.

Sistemas de información

Integran datos.

Estadística

Permite evaluar resultados.

La integración puede expresarse:

CRM + BI + Data Mining + Machine Learning



Decisiones comerciales

49. Conclusiones

La analítica comercial y de marketing permite transformar información dispersa sobre clientes, mercados y campañas en decisiones orientadas a mejorar la adquisición, conversión, retención y rentabilidad.

Indicadores como CAC, CLV, churn, conversión, ROAS, CTR y ticket promedio ofrecen información cuantitativa sobre el desempeño comercial. Sin embargo, su verdadero valor aparece cuando se combinan con técnicas de segmentación, experimentación y modelos predictivos.

Las organizaciones pueden evolucionar desde estrategias masivas hacia acciones personalizadas mediante:

Datos → Segmentación → Predicción → Personalización

Asimismo, el análisis del customer journey permite comprender cómo los clientes interactúan con diferentes canales y detectar puntos críticos en el proceso de conversión.

La analítica comercial debe orientarse a resultados empresariales y no limitarse a métricas digitales aisladas. El objetivo final consiste en mejorar simultáneamente la experiencia del cliente y el desempeño económico.

Por ello:

Analítica comercial = Conocimiento del cliente + Medición + Predicción + Acción

Su integración con Business Intelligence, inteligencia artificial y aprendizaje automático convierte al marketing en una función cada vez más cuantitativa, medible y estratégica.

Referencias bibliográficas

Chaffey, D., & Ellis-Chadwick, F. (2022). *Digital marketing: Strategy, implementation and practice* (8th ed.). Pearson.

Farris, P. W., Bendle, N. T., Pfeifer, P. E., & Reibstein, D. J. (2020). *Marketing metrics: The manager's guide to measuring marketing performance* (4th ed.). Pearson.

Han, J., Pei, J., & Tong, H. (2022). *Data mining: Concepts and techniques* (4th ed.). Morgan Kaufmann.

Kotler, P., Kartajaya, H., & Setiawan, I. (2021). *Marketing 5.0: Technology for humanity*. Wiley.

Sharda, R., Delen, D., & Turban, E. (2024). *Business intelligence, analytics, data science, and AI* (5th ed.). Pearson.

Shmueli, G., Bruce, P. C., Gedeck, P., & Patel, N. R. (2023). *Data mining for business analytics: Concepts, techniques, and applications in Python*. Wiley.

CAPÍTULO 9

Analítica financiera y de riesgos

Gina Maribel Carrasco Echeverría

gmcarascoe@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0000-0003-4512-558X>

1. Introducción

La analítica financiera y de riesgos integra herramientas estadísticas, modelos predictivos y sistemas de información para mejorar la calidad de las decisiones relacionadas con liquidez, rentabilidad, inversión, crédito, fraude y exposición a eventos adversos.

En entornos empresariales complejos, la información financiera ya no se utiliza únicamente para describir resultados pasados. También permite anticipar problemas, identificar patrones de riesgo y evaluar escenarios futuros.

El proceso puede representarse como:

Datos financieros → Análisis → Modelos → Evaluación de riesgo → Decisión

La analítica financiera responde preguntas como:

¿Qué clientes presentan mayor probabilidad de incumplimiento?

¿Cuál es el comportamiento esperado del flujo de caja?

¿Qué variables explican la rentabilidad?

¿Qué transacciones podrían ser fraudulentas?

¿Qué escenarios pueden afectar la estabilidad financiera?

2. Concepto de analítica financiera

La analítica financiera comprende el uso de datos, indicadores y modelos para interpretar el desempeño económico y apoyar decisiones financieras.

Puede expresarse como:

Analítica financiera = Datos + Estadística + Modelos + Decisiones

Sus principales aplicaciones incluyen:

- análisis de estados financieros;
- pronóstico;
- evaluación de inversiones;
- riesgo crediticio;

- fraude;
- liquidez;
- rentabilidad;
- planificación financiera.

3. Fuentes de datos financieros

Los datos pueden provenir de:

- estados financieros;
- ERP;
- sistemas contables;
- bancos;
- sistemas de facturación;
- historial crediticio;
- cartera;
- mercados financieros;
- plataformas de pago.

Por ejemplo:

$$\text{Ventas} + \text{Costos} + \text{Cartera} + \text{Caja} + \text{Deuda}$$

pueden integrarse en un sistema analítico.

4. Estados financieros

Los principales estados financieros son:

- estado de resultados;
- balance general;
- flujo de efectivo.

Estos proporcionan información sobre:

Rentabilidad
Liquidez
Endeudamiento
Eficiencia

La analítica permite estudiar su evolución histórica y proyectar escenarios.

5. Indicadores de liquidez

Uno de los principales indicadores es:

$$Razon corriente = \frac{Activo corriente}{Pasivo corriente}$$

Si:

$$Activo corriente = 120000$$

y:

$$Pasivo corriente = 80000$$

entonces:

$$Razon corriente = 1.5$$

Esto significa que la empresa dispone de \$1,50 en activos corrientes por cada dólar de obligación de corto plazo.

6. Prueba ácida

Puede calcularse:

$$Prueba ácida = \frac{Activo corriente - Inventarios}{Pasivo corriente}$$

Este indicador excluye inventarios y ofrece una visión más estricta de liquidez.

7. Indicadores de endeudamiento

Puede utilizarse:

$$Endeudamiento = \frac{Pasivo total}{Activo total} \times 100$$

Si:

$$Pasivo = 300000$$

y:

$$Activo = 500000$$

entonces:

$$\text{Endeudamiento} = 60\%$$

Este resultado indica que el 60 % de los activos está financiado mediante obligaciones.

8. Rentabilidad

El margen neto puede calcularse:

$$\text{Margen neto} = \frac{\text{Utilidad neta}}{\text{Ventas}} \times 100$$

Si una empresa obtiene:

$$\text{Utilidad} = 50000$$

y:

$$\text{Ventas} = 500000$$

entonces:

$$\text{Margen neto} = 10\%$$

9. ROA

El rendimiento sobre activos se expresa:

$$\text{ROA} = \frac{\text{Utilidad neta}}{\text{Activo total}} \times 100$$

Este indicador permite evaluar la eficiencia con que los activos generan resultados.

10. ROE

El rendimiento sobre patrimonio se calcula:

$$\text{ROE} = \frac{\text{Utilidad neta}}{\text{Patrimonio}} \times 100$$

Por ejemplo:

$$\begin{aligned}\text{ROE} &= \frac{60000}{300000} \times 100 \\ \text{ROE} &= 20\%\end{aligned}$$

11. Análítica de flujo de caja

El flujo de caja constituye un elemento central para la continuidad empresarial.

Puede modelarse:

$$Flujo_t = Ingresos_t - Egresos_t$$

La analítica permite proyectar:

$$Flujo_{t+1}$$

considerando:

- ventas;
- cobros;
- pagos;
- estacionalidad;
- deuda.

12. Pronóstico financiero

Los modelos de series temporales pueden utilizarse para estimar:

- ingresos;
- gastos;
- utilidades;
- caja;
- cuentas por cobrar.

Por ejemplo:

$$Ventas_{t+1} = f(V, e, ntas_t, Tendencia, Estacionalidad)$$

Esto facilita elaborar presupuestos más dinámicos.

13. Presupuesto y análisis de desviaciones

Puede compararse:

Real

con:

Presupuesto

La variación se expresa:

$$Variación = Real - Presupuesto$$

Y porcentualmente:

$$Variación\% = \frac{Real - Presupuesto}{Presupuesto} \times 100$$

Esto permite identificar desviaciones significativas.

14. Analítica de escenarios

La empresa puede evaluar distintos escenarios:

Optimista

$$Ventas + 15\%$$

Base

$$Ventas\ constantes$$

Pesimista

$$Ventas - 15\%$$

Luego puede analizar el impacto sobre:

- utilidad;
- caja;
- deuda;
- inventario.

15. Análisis de sensibilidad

Permite estudiar cómo cambia un resultado cuando cambia una variable.

Por ejemplo:

$$Utilidad = f(P, r, Precio, Costo, Demanda)$$

Si el costo aumenta:

$$10\%$$

puede estimarse su impacto sobre margen.

Esto ayuda a identificar variables críticas.

16. Concepto de riesgo financiero

El riesgo representa la posibilidad de que los resultados sean diferentes de los esperados.

Puede expresarse:

$$Riesgo = Probabilidad \times Impacto$$

Entre los principales tipos se encuentran:

- crédito;
- mercado;
- liquidez;
- operacional;
- fraude.

17. Riesgo crediticio

El riesgo crediticio representa la posibilidad de incumplimiento.

Un modelo puede estimar:

$$P(Default) = f(I, n, g, resoDeudaHistorialAntigüedad)$$

Por ejemplo:

$$P(Default) = 0.72$$

Esto puede indicar un nivel elevado de riesgo.

18. Scoring crediticio

El scoring asigna una puntuación a cada solicitante.

Ejemplo:

Cliente	Score	Riesgo
A	820	Bajo
B	650	Medio
C	480	Alto

El score puede construirse mediante:

- regresión logística;

- árboles;
- Random Forest;
- redes neuronales.

19. Regresión logística en crédito

Puede utilizarse:

$$P(\text{Impago}) = \frac{1}{1 + e^{-z}}$$

donde:

$$z = \beta_0 + \beta_1 \text{Ingreso} + \beta_2 \text{Deuda} + \beta_3 \text{Historial}$$

El resultado permite clasificar solicitudes según probabilidad estimada.

20. Riesgo de mercado

El riesgo de mercado surge de cambios en:

- precios;
- tasas de interés;
- tipos de cambio;
- valores financieros.

Por ejemplo:

$$\text{Valor cartera} = f(P, r, \text{ecioTasaTipo de cambio})$$

Variaciones adversas pueden producir pérdidas.

21. Value at Risk

El **Value at Risk (VaR)** estima una pérdida potencial bajo cierto nivel de confianza.

Por ejemplo:

VaR diario de \$10.000 al 95 %.

Puede interpretarse como que, bajo las condiciones del modelo, existe un 5 % de probabilidad de que la pérdida diaria supere los \$10.000.

No representa la pérdida máxima posible.

22. VaR paramétrico simplificado

Puede expresarse:

$$VaR = z_{\alpha}\sigma V$$

donde:

- z_{α} : valor crítico;
- σ : volatilidad;
- V : valor de la posición.

Supóngase:

$$\begin{aligned} V &= 100000 \\ \sigma &= 0.02 \\ z &= 1.645 \end{aligned}$$

Entonces:

$$\begin{aligned} VaR &= 1.645(0.02)(100000) \\ VaR &= 3290 \end{aligned}$$

23. Riesgo de liquidez

El riesgo de liquidez aparece cuando una organización no puede cumplir sus obligaciones oportunamente.

Puede analizarse mediante:

- caja;
- vencimientos;
- cuentas por cobrar;
- cuentas por pagar;
- líneas de crédito.

Un indicador sencillo:

$$Cobertura = \frac{Caja\ disponible}{Obligaciones\ inmediatas}$$

24. Riesgo operacional

El riesgo operacional se relaciona con pérdidas derivadas de:

- procesos;
- personas;
- sistemas;

- eventos externos.

Ejemplos:

- errores;
- fallas tecnológicas;
- fraude;
- interrupciones.

Puede representarse:

$$\text{Riesgo operacional} = f(F, \text{frecuencia}, \text{Severidad})$$

25. Detección de fraude

La analítica puede identificar transacciones anómalas.

Variables posibles:

- monto;
- hora;
- ubicación;
- frecuencia;
- dispositivo;
- comportamiento histórico.

Un modelo puede estimar:

$$P(\text{Fraude}) = f(X_1, \dots, X_k)$$

26. Ejemplo de detección de fraude

Supóngase una transacción:

$$\text{Monto} = \$4500$$

realizada:

$$03:00 \text{ AM}$$

desde una ubicación no habitual.

Si el patrón histórico del cliente es diferente, el sistema puede asignar:

$$P(\text{Fraude}) = 0.91$$

y activar una alerta.

27. Detección de anomalías

No todos los fraudes tienen ejemplos históricos suficientes.

Por ello pueden utilizarse técnicas de anomalías.

Una regla básica puede ser:

$$|X - \mu| > 3\sigma$$

Los casos extremos se investigan.

En escenarios complejos pueden emplearse algoritmos no supervisados.

28. Machine learning financiero

Los principales modelos incluyen:

- regresión logística;
- árboles;
- Random Forest;
- Gradient Boosting;
- redes neuronales;
- modelos de series temporales.

Pueden aplicarse a:

Credito
Fraude
Pronostico
Riesgo

29. Evaluación de modelos crediticios

Supóngase:

Modelo	Accuracy	Recall	F1	AUC
Regresión logística	0,82	0,76	0,78	0,86
Árbol	0,79	0,73	0,75	0,81
Random Forest	0,88	0,84	0,85	0,92
Red neuronal	0,89	0,86	0,87	0,93

La selección final debe considerar no solo precisión, sino también interpretabilidad.

30. Importancia de la explicabilidad

En decisiones financieras, explicar un resultado puede ser tan importante como predecirlo correctamente.

Por ejemplo:

Crédito rechazado.

La organización debería poder identificar factores como:

- nivel de deuda;
- historial;
- capacidad de pago.

Por ello:

$$\text{Modelo financiero} = \text{Precisión} + \text{Explicabilidad} + \text{Control}$$

31. Stress testing

Las pruebas de estrés permiten evaluar escenarios extremos.

Por ejemplo:

Ventas – 30%
Tasa + 5 puntos
Cartera vencida + 20%

Luego se analiza el impacto en:

- liquidez;
- solvencia;
- utilidad.

Esto permite anticipar vulnerabilidades.

32. Dashboard financiero

Un dashboard puede incluir:

Indicador	Resultado
Ventas	\$1.500.000
Utilidad	\$180.000
Margen neto	12 %
Liquidez	1,6

Endeudamiento	55 %
Cartera vencida	6 %
Flujo de caja	\$95.000

Esto facilita seguimiento ejecutivo.

33. Analítica de cartera

La cartera puede clasificarse por antigüedad:

Días vencidos	Saldo
0–30	\$90.000
31–60	\$35.000
61–90	\$15.000
>90	\$20.000

Puede calcularse:

$$Cartera\ vencida = \frac{Saldo\ vencido}{Cartera\ total} \times 100$$

34. Caso aplicado

Considérese una empresa con:

$$\begin{aligned} Cartera\ total &= \$500000 \\ Cartera\ vencida &= \$60000 \end{aligned}$$

Entonces:

$$\begin{aligned} CV &= \frac{60000}{500000} \times 100 \\ CV &= 12\% \end{aligned}$$

La empresa puede utilizar modelos para identificar clientes con mayor riesgo de mora.

35. Modelo de cobranza

Puede estimarse:

$$P(Mora) = f(D, i, a, sDeudaHistorialCompras)$$

Clientes con:

$$P(Mora) > 0.80$$

podrían recibir atención prioritaria.

Esto permite dirigir recursos de cobranza hacia casos más críticos.

36. Analítica y Business Intelligence financiera

Los datos pueden integrarse mediante:

ERP + Contabilidad + Bancos + Cartera



Data Warehouse



Power BI



Dashboard financiero

Esto permite comparar información prácticamente en tiempo real.

37. Uso de Orange

Orange puede utilizarse para problemas financieros.

Un flujo podría ser:

File



Select Columns



Impute



Rank



Logistic Regression

Random Forest
Neural Network



Test and Score



Confusion Matrix



Predictions

Puede utilizarse para predecir:

- mora;
- crédito;
- fraude;
- riesgo.

38. Riesgos climáticos y financieros

Las organizaciones también enfrentan riesgos asociados al clima.

Pueden incluir:

Riesgo físico

- inundaciones;
- sequías;
- eventos extremos.

Riesgo de transición

- regulación;
- cambios tecnológicos;
- impuestos;
- cambios de mercado.

Estos factores pueden afectar:

Ingresos
Costos
Activos
Financiamiento

39. Sostenibilidad e información financiera

Los marcos contemporáneos de divulgación de sostenibilidad refuerzan la conexión entre riesgos ambientales y desempeño financiero.

En este contexto, el análisis puede integrar:

Información financiera + Información climática

para evaluar posibles efectos sobre:

- flujos;
- activos;
- costos;
- riesgos.

40. Ética en analítica financiera

Los modelos financieros pueden afectar directamente a personas y empresas.

Por ello deben evitar:

- discriminación;
- sesgos;
- uso indebido de datos;
- decisiones opacas.

La analítica responsable debe considerar:

Precisión + Equidad + Transparencia + Seguridad

41. Gobierno de modelos

Un modelo debe ser supervisado durante todo su ciclo.

Esto incluye:

Desarrollo



Validación



Implementación



Monitoreo



Actualización

Un modelo que funcionó adecuadamente puede deteriorarse si cambia el comportamiento del mercado.

42. Beneficios empresariales

La analítica financiera puede contribuir a:

- mejorar pronósticos;
- reducir pérdidas;
- priorizar cobranza;
- detectar fraude;
- controlar liquidez;
- evaluar escenarios;
- mejorar asignación de capital.

Puede sintetizarse:

Mejor información + Mejor evaluación de riesgo = Mejor decisión financiera

43. Limitaciones

Entre sus limitaciones se encuentran:

- datos incompletos;
- modelos inestables;
- eventos inesperados;
- sesgos históricos;
- dificultad de interpretación;
- dependencia de supuestos.

Ningún modelo elimina completamente la incertidumbre.

Por tanto:


Predicción ≠ Certeza

44. Tendencias

Entre las principales tendencias se encuentran:

- IA en gestión financiera;
- detección de fraude en tiempo real;
- scoring alternativo;
- automatización;
- explainable AI;
- stress testing automatizado;
- integración ESG-finanzas.

La evolución puede representarse:



45. Relación con capítulos anteriores

La analítica financiera integra herramientas de:

Estadística

Para indicadores y estimaciones.

Sistemas de información

Para integrar datos.

Minería de datos

Para descubrir patrones.

Modelos predictivos

Para anticipar riesgo.

Business Intelligence

Para visualizar resultados.

Puede expresarse:

Finanzas + Estadística + BI + ML



Gestión financiera basada en datos

46. Conclusiones

La analítica financiera y de riesgos permite transformar datos económicos y financieros en información útil para anticipar problemas y mejorar decisiones empresariales.

El análisis de liquidez, rentabilidad, endeudamiento, cartera y flujo de caja proporciona una visión descriptiva del desempeño, mientras que los modelos predictivos permiten estimar escenarios futuros.

En materia de riesgo, la analítica puede utilizarse para evaluar:

Crédito + Mercado + Liquidez + Operaciones + Fraude

La incorporación de machine learning amplía la capacidad para detectar patrones complejos, aunque también incrementa la necesidad de explicabilidad y gobierno.

La relación general puede representarse:

Datos → Indicadores → Modelos → Riesgo → Decisión

En consecuencia, la analítica financiera no debe limitarse a producir reportes históricos. Su verdadero valor aparece cuando permite anticipar escenarios, priorizar acciones y reducir la incertidumbre.

De esta manera:

Analítica financiera = Medición + Predicción + Gestión de riesgo + Decisión

se convierte en un componente esencial de la gestión empresarial basada en datos.

Referencias bibliográficas

Hull, J. C. (2023). *Risk management and financial institutions* (6th ed.). Wiley.

IFRS Foundation. (2023). *IFRS S2 climate-related disclosures*. International Sustainability Standards Board.

James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). *An introduction to statistical learning: With applications in Python*. Springer. <https://doi.org/10.1007/978-3-031-38747-0>

Sharda, R., Delen, D., & Turban, E. (2024). *Business intelligence, analytics, data science, and AI* (5th ed.). Pearson.

Shmueli, G., Bruce, P. C., Gedeck, P., & Patel, N. R. (2023). *Data mining for business analytics: Concepts, techniques, and applications in Python*. Wiley.

Saunders, A., Cornett, M. M., & Erhemjamts, O. (2021). *Financial institutions management: A risk management approach* (10th ed.). McGraw Hill.

CAPÍTULO 10

Analítica operacional y comportamiento del consumidor

Wendy Lorena Ocampo Ulloa

wocampo@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0000-0002-4600-2605>

María Alexandra Rodríguez Gómez

mrodriguez@utb.edu.ec

Universidad Técnica de Babahoyo

<https://orcid.org/0000-0001-8171-618X>

1. Introducción

La analítica operacional y el análisis del comportamiento del consumidor constituyen dos áreas estrechamente relacionadas dentro de la gestión empresarial basada en datos. La primera se orienta a mejorar procesos, recursos, inventarios, tiempos y eficiencia; la segunda busca comprender cómo los consumidores toman decisiones, interactúan con los canales y responden a productos, precios y experiencias.

La integración de ambas perspectivas permite comprender no solamente qué ocurre dentro de la empresa, sino también cómo las decisiones operativas afectan la experiencia del cliente.

El proceso puede representarse como:

Datos operacionales + Datos del consumidor



Analítica



Predicción



Optimización



Mejor experiencia

Las empresas modernas necesitan coordinar operaciones y comportamiento del consumidor porque problemas como retrasos, falta de inventario o atención deficiente pueden modificar directamente la percepción y lealtad de los clientes.

2. Concepto de analítica operacional

La analítica operacional utiliza datos generados por los procesos internos para mejorar decisiones relacionadas con:

- producción;
- inventarios;
- logística;
- distribución;
- servicio;
- mantenimiento;
- calidad;
- productividad.

Puede expresarse como:

$$\text{Analítica operacional} = \text{Datos} + \text{Procesos} + \text{Modelos} + \text{Decisiones}$$

Su finalidad consiste en aumentar eficiencia, reducir costos y mejorar niveles de servicio.

3. Fuentes de datos operacionales

Entre las principales fuentes se encuentran:

- ERP;
- inventarios;
- órdenes de compra;
- producción;
- sistemas logísticos;
- GPS;
- sensores;
- CRM;
- sistemas de atención.

Por ejemplo:

$$\text{Inventario} + \text{Ventas} + \text{Entregas} + \text{Clientes}$$

pueden integrarse para analizar el desempeño de una cadena comercial.

4. Indicadores operacionales

Los indicadores permiten medir eficiencia y desempeño.

Entre los principales se encuentran:

Productividad

$$Productividad = \frac{Output}{Input}$$

Utilización

$$Utilización = \frac{Capacidad\ utilizada}{Capacidad\ disponible} \times 100$$

Eficiencia

$$Eficiencia = \frac{Resultado\ real}{Resultado\ esperado} \times 100$$

Estos indicadores permiten comparar procesos y períodos.

5. Tiempo de ciclo

El tiempo de ciclo mide cuánto tarda un proceso en completarse.

Puede expresarse:

$$TC = Tiempo\ final - Tiempo\ inicial$$

Por ejemplo, si un pedido se recibe a las 09:00 y se despacha a las 13:00:

$$TC = 4\ horas$$

Reducir este tiempo puede mejorar la experiencia del cliente.

6. Nivel de servicio

Un indicador fundamental es:

$$Nivel\ de\ servicio = \frac{Pedidos\ atendidos}{Pedidos\ totales} \times 100$$

Si una empresa recibe:

1000

pedidos y atiende correctamente:

940

entonces:

$$\text{Nivel de servicio} = 94\%$$

7. Entregas a tiempo

Puede calcularse:

$$OTD = \frac{\text{Entregas a tiempo}}{\text{Entregas totales}} \times 100$$

Si:

$$\text{Entregas} = 500$$

y:

$$\text{A tiempo} = 460$$

entonces:

$$OTD = 92\%$$

Este indicador afecta directamente la satisfacción del cliente.

8. Analítica de inventarios

La gestión de inventarios busca equilibrar:

Disponibilidad

y:

Costo

Un exceso de inventario genera:

- almacenamiento;
- obsolescencia;
- capital inmovilizado.

Una falta de inventario puede generar:

- ventas perdidas;

- insatisfacción;
- abandono.

9. Rotación de inventarios

Puede calcularse:

$$Rotación' = \frac{Costo\ de\ ventas}{Inventario\ promedio}$$

Si:

$$Costo\ de\ ventas = 600000$$

y:

$$Inventario\ promedio = 100000$$

entonces:

$$Rotación' = 6$$

Esto significa que el inventario rota aproximadamente seis veces durante el período analizado.

10. Días de inventario

Puede calcularse:

$$Días\ de\ inventario' = \frac{365}{Rotación'}$$

Si:

$$Rotación' = 6$$

entonces:

$$Días' = 60.83$$

aproximadamente 61 días.

11. Punto de pedido

El punto de pedido puede expresarse:

$$ROP = \text{Demanda durante lead time} + \text{Stock de seguridad}$$

Por ejemplo:

$$\begin{aligned}\text{Demanda diaria} &= 20 \\ \text{Lead time} &= 5 \\ \text{Stock seguridad} &= 30\end{aligned}$$

Entonces:

$$\begin{aligned}ROP &= (20)(5) + 30 \\ ROP &= 130\end{aligned}$$

Cuando el inventario llega a 130 unidades debería generarse una nueva orden.

12. Pronóstico de demanda

La analítica operacional utiliza modelos predictivos para estimar demanda futura.

Puede representarse:

$$\text{Demanda}_{t+1} = f(D, e, m, \text{and}_t \text{ Precio Promoción Temporada})$$

Esto permite ajustar:

- inventario;
- producción;
- personal;
- compras.

13. Error de pronóstico

Para evaluar pronósticos puede utilizarse:

$$MAE = \frac{1}{n} \sum |Y_i - \hat{Y}_i|$$

También:

$$RMSE = \sqrt{\frac{1}{n} \sum (Y_i - \hat{Y}_i)^2}$$

Cuanto menor sea el error, mayor será generalmente la precisión del pronóstico.

14. Analítica logística

La logística puede analizar:

- rutas;
- transporte;
- combustible;
- entregas;
- tiempos;
- costos.

Por ejemplo:

$$\text{Costo logístico} = \text{Transporte} + \text{Almacenamiento} + \text{Manipulación}$$

La analítica puede identificar rutas menos eficientes.

15. Optimización de rutas

Un problema logístico busca minimizar:

Costo

o:

Distancia

sujeto a restricciones como:

- capacidad;
- horarios;
- número de vehículos;
- prioridades.

Puede representarse:

$$\text{Min } Z = \sum c_{ij} x_{ij}$$

donde c_{ij} representa el costo de trasladarse entre dos puntos.

16. Analítica de colas

Los sistemas de servicio pueden presentar filas de espera.

Ejemplos:

- bancos;
- hospitales;
- restaurantes;
- call centers.

Dos parámetros fundamentales son:

$$\lambda = \text{Tasa de llegada}$$
$$\mu = \text{Tasa de servicio}$$

Si la capacidad es insuficiente, los tiempos de espera aumentan.

17. Tiempo de espera y experiencia

La percepción del cliente puede deteriorarse cuando aumenta:

Tiempo de espera

Por ello puede analizarse:

$$\text{Satisfacción} = f(T, i, e, mpo, \text{Calidad Atención}, \text{Precio})$$

Una empresa podría descubrir que la satisfacción cae significativamente después de cierto tiempo de espera.

18. Comportamiento del consumidor

El comportamiento del consumidor estudia cómo las personas:

- identifican necesidades;
- buscan información;
- comparan opciones;
- compran;
- utilizan;
- evalúan productos.

Puede representarse:

Necesidad



Búsqueda



Evaluación



Compra



Experiencia



Recompra

19. Factores que influyen en el consumidor

Entre los principales factores se encuentran:

Psicológicos

- motivación;
- percepción;
- aprendizaje;
- actitudes.

Sociales

- familia;
- grupos;
- redes.

Culturales

- valores;
- costumbres.

Económicos

- ingreso;
- precio;
- poder adquisitivo.

La analítica permite observar parte de estos efectos mediante datos conductuales.

20. Datos conductuales

Los datos de comportamiento pueden incluir:

- clics;
- búsquedas;
- compras;
- devoluciones;
- tiempo de navegación;
- frecuencia;
- productos vistos.

Puede representarse:

$$\text{Comportamiento} = f(\text{Interacciones})$$

Esto permite complementar encuestas y entrevistas con evidencia observable.

21. Clickstream

El análisis clickstream estudia la secuencia de acciones realizadas en un entorno digital.

Ejemplo:

$$\text{Inicio} \rightarrow \text{Producto} \rightarrow \text{Carrito} \rightarrow \text{Pago}$$

Otro usuario podría realizar:

$$\text{Inicio} \rightarrow \text{Producto} \rightarrow \text{Salida}$$

El análisis permite detectar puntos de abandono.

22. Customer Journey Analytics

El análisis del customer journey estudia todos los puntos de contacto.

Por ejemplo:

Instagram



Web



WhatsApp



Tienda



Compra

La empresa puede identificar qué combinaciones generan mejores resultados.

23. Segmentación conductual

Los clientes pueden agruparse según:

- frecuencia;
- recencia;
- ticket;
- canal;
- interacción;
- sensibilidad al precio.

Por ejemplo:

Grupo 1

Clientes frecuentes.

Grupo 2

Clientes sensibles a descuentos.

Grupo 3

Clientes digitales.

Grupo 4

Clientes en riesgo de abandono.

Esto facilita estrategias diferenciadas.

24. Análisis RFM

Puede utilizarse:

R = Recencia

F = Frecuencia

M = Valor monetario

Los clientes pueden recibir puntuaciones.

Por ejemplo:

$$R = 5, F = 5, M = 5$$

indica un cliente de alto valor.

25. Sensibilidad al precio

La respuesta del consumidor al precio puede evaluarse mediante elasticidad:

$$E_p = \frac{\% \Delta Q}{\% \Delta P}$$

Si:

$$E_p = -1.5$$

una variación del 1 % en precio se relaciona aproximadamente con una variación de 1,5 % en sentido contrario en la cantidad demandada.

26. Promociones y comportamiento

Puede analizarse:

$$Respuesta = f(D, e, s, cuentaProductoClienteCanal)$$

Una promoción del 20 % no necesariamente genera el mismo resultado en todos los segmentos.

Por ello, la empresa puede personalizar incentivos.

27. Analítica de satisfacción

La satisfacción puede medirse mediante escalas.

Por ejemplo:

$$1 = Muy insatisfecho$$

hasta:

$$5 = Muy satisfecho$$

Puede calcularse:

$$Media = \frac{\sum X_i}{n}$$

Pero también pueden analizarse relaciones con:

- entrega;
- atención;
- calidad;
- precio.

28. Net Promoter Score

El NPS clasifica clientes como:

- promotores;
- pasivos;
- detractores.

Se calcula:

$$NPS = \% \text{ Promotores} - \% \text{ Detractores}$$

Si:

$$\text{Promotores} = 60\%$$

y:

$$\text{Detractores} = 20\%$$

entonces:

$$NPS = 40$$

29. Análisis de reseñas

Los comentarios de clientes pueden analizarse mediante minería de texto.

Ejemplo:

“El producto es bueno pero la entrega tardó demasiado”.

El análisis puede detectar dos dimensiones:

$$\begin{aligned} \text{Producto} &= \text{Positivo} \\ \text{Entrega} &= \text{Negativo} \end{aligned}$$

Esto permite identificar causas específicas de insatisfacción.

30. Análisis de sentimiento

Los comentarios pueden clasificarse en:

Positivo
Neutral
Negativo

Por ejemplo:

Sentimiento	Porcentaje
Positivo	65 %
Neutral	20 %
Negativo	15 %

La evolución temporal puede indicar cambios en percepción.

31. Relación entre operación y satisfacción

Supóngase:

Tiempo entrega	Satisfacción
1 día	4,8
2 días	4,5
3 días	4,1
5 días	3,2

Puede observarse una tendencia:

Mayor tiempo → Menor satisfacción

Esto puede evaluarse mediante correlación o regresión.

32. Correlación aplicada

Puede calcularse:

$$r_{\text{Tiempo,Satisfacción}}$$

Si:

$$r = -0.72$$

existiría una relación negativa fuerte.

Sin embargo:

$$\textit{Correlación} \neq \textit{Causalidad}$$

La interpretación debe considerar otros factores.

33. Modelos predictivos de satisfacción

Puede plantearse:

$$\textit{Satisfacción} = f\left(T, i, e, mpo, \textit{Calidad}, \textit{Precio}, \textit{Atención}\right)$$

Un modelo podría identificar cuál variable presenta mayor importancia predictiva.

Esto permite priorizar acciones.

34. Predicción de abandono

Puede estimarse:

$$P(\textit{Churn}) = f\left(Q, u, e, jas, \textit{Compras}, \textit{Tiempo entrega}, \textit{Satisfacción}\right)$$

Si:

$$P(\textit{Churn}) = 0.87$$

la empresa podría activar una acción de retención.

35. Caso aplicado

Considérese una empresa minorista con:

10.000 *pedidos*

Datos:

Indicador	Resultado
Entregas a tiempo	8.900
Pedidos completos	9.300
Devoluciones	450

Satisfacción	4,1/5
Cientes recurrentes	6.500

36. Entregas a tiempo

$$OTD = \frac{8900}{10000} \times 100$$

$$OTD = 89\%$$

37. Pedidos completos

$$PC = \frac{9300}{10000} \times 100$$

$$PC = 93\%$$

38. Tasa de devolución

$$TD = \frac{450}{10000} \times 100$$

$$TD = 4.5\%$$

Estos indicadores deben analizarse conjuntamente.

39. Relación con comportamiento

Supóngase que los clientes con entregas tardías presentan:

$$Satisfacción' = 3.2$$

mientras que aquellos con entrega puntual presentan:

$$Satisfacción' = 4.6$$

Esto sugiere que mejorar la logística podría influir favorablemente en la experiencia.

40. Modelo predictivo aplicado

Se puede construir:

$$Recompra = f(E, n, t, rega, Satisfacción', Devoluciones, Precio)$$

La variable objetivo sería:

$$Recompra = Si/No$$

El modelo podría identificar clientes con mayor probabilidad de volver a comprar.

41. Comparación de algoritmos

Ejemplo:

Modelo	Accuracy	F1	AUC
Regresión logística	0,80	0,78	0,84
Árbol	0,79	0,77	0,81
Random Forest	0,86	0,84	0,90
Red neuronal	0,88	0,86	0,92


En este escenario, la red neuronal presenta mejor desempeño.

La elección final debe considerar también interpretabilidad y costo.

42. Uso de Orange

Orange puede utilizarse para integrar información operacional y del consumidor.

Un flujo podría ser:





Confusion Matrix



Predictions

Las variables predictoras podrían ser:

- tiempo de entrega;
- devoluciones;
- frecuencia;
- satisfacción;
- ticket.

43. Business Intelligence operacional

Los indicadores pueden integrarse en un dashboard.

KPI	Resultado	Meta
OTD	89 %	95 %
Pedidos completos	93 %	97 %
Devoluciones	4,5 %	<3 %
Satisfacción	4,1	4,5
Recompra	65 %	70 %

Esto permite relacionar desempeño interno y experiencia externa.

44. Analítica en tiempo real

Los sistemas actuales permiten monitorear:

Pedido → Preparación → Despacho → Transporte → Entrega

Si ocurre un retraso:

Sistema detecta



Alerta



Acción

Esto puede prevenir insatisfacción.

45. Inteligencia artificial y comportamiento

La IA puede utilizarse para:

- recomendaciones;
- predicción de demanda;
- clasificación de clientes;
- análisis de sentimiento;
- asistentes virtuales;
- personalización.

Por ejemplo:

Cliente + Historial + Contexto



Recomendación

La personalización puede incrementar relevancia, pero requiere un uso responsable de datos.

46. Optimización integrada

La verdadera ventaja aparece cuando la empresa optimiza simultáneamente:

Costo
Servicio
Inventario
Satisfacción

Por ejemplo, reducir inventarios al mínimo podría disminuir costos, pero aumentar quiebres de stock.

Por ello:

Óptimo operacional ≠ Mínimo costo

El objetivo debe considerar la experiencia del cliente.

47. Trade-offs operacionales

Las empresas enfrentan relaciones de compromiso.

Por ejemplo:

Inventario alto → Mayor disponibilidad + Mayor costo

Mientras:

Inventario bajo → Menor costo + Mayor riesgo de faltantes

La analítica permite cuantificar estas relaciones.

48. Ética y privacidad

El análisis del comportamiento utiliza información sobre individuos.

Por ello se deben considerar:

- consentimiento;
- privacidad;
- transparencia;
- protección;
- seguridad.

La capacidad de predecir comportamiento no significa que cualquier uso de los datos sea apropiado.

La analítica responsable requiere:

Utilidad + Privacidad + Equidad + Transparencia

49. Limitaciones

Entre las principales limitaciones se encuentran:

- datos fragmentados;
- cambios de conducta;
- sesgos;
- indicadores incompletos;
- modelos poco interpretables;
- problemas de calidad.

El comportamiento humano puede cambiar rápidamente.

Por ello:

Modelo pasado ≠ Garantía futura

50. Tendencias actuales

Entre las principales tendencias se encuentran:

- analítica en tiempo real;
- IoT;
- digital twins;
- IA generativa;
- hiperpersonalización;
- automatización logística;
- customer journey analytics;
- demand sensing;
- modelos de comportamiento.

La evolución puede representarse:

Operación reactiva



Operación medida



Operación predictiva



Operación inteligente

51. Relación con capítulos anteriores

La analítica operacional y del consumidor integra:

Estadística

Para analizar variaciones y relaciones.

Sistemas de información

Para capturar datos.

Minería de datos

Para identificar patrones.

Modelos predictivos

Para anticipar demanda y comportamiento.

Business Intelligence

Para monitorear KPI.

Marketing Analytics

Para comprender clientes.

Puede resumirse:

Operaciones + Cliente + Datos



Decisión integral

52. Conclusiones

La analítica operacional y el comportamiento del consumidor deben analizarse de forma integrada, debido a que las decisiones internas de una organización afectan directamente la experiencia del cliente.

Indicadores como productividad, tiempos de ciclo, inventarios, entregas a tiempo y devoluciones permiten evaluar el desempeño operacional. Paralelamente, métricas de satisfacción, recompra, churn y comportamiento digital permiten comprender las respuestas del consumidor.

La integración puede representarse como:

Operaciones → Experiencia → Comportamiento → Resultado

Los modelos predictivos permiten anticipar demanda, identificar riesgo de abandono y estimar probabilidad de recompra, mientras que Business Intelligence facilita el seguimiento continuo.

Por ello, la gestión moderna debe buscar:

Eficiencia operacional + Satisfacción del cliente + Rentabilidad

y no optimizar cada dimensión de manera aislada.

En consecuencia, la analítica operacional y del consumidor constituye una herramienta fundamental para diseñar organizaciones más eficientes, ágiles y centradas en el cliente.

Referencias bibliográficas

Chaffey, D., & Ellis-Chadwick, F. (2022). *Digital marketing: Strategy, implementation and practice* (8th ed.). Pearson.

Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts.

Kotler, P., Kartajaya, H., & Setiawan, I. (2021). *Marketing 5.0: Technology for humanity*. Wiley.

Sharda, R., Delen, D., & Turban, E. (2024). *Business intelligence, analytics, data science, and AI* (5th ed.). Pearson.

Shmueli, G., Bruce, P. C., Gedeck, P., & Patel, N. R. (2023). *Data mining for business analytics: Concepts, techniques, and applications in Python*. Wiley.

Slack, N., Brandon-Jones, A., & Burgess, N. (2022). *Operations management* (10th ed.). Pearson.

CAPÍTULO 11

Estrategia empresarial basada en datos

Ely Israel Borja Salinas

ely.borjas@ug.edu.ec

Universidad de Guayaquil

<https://orcid.org/0000-0003-1465-9538>

1. Introducción

La estrategia empresarial basada en datos representa la integración de información, analítica, tecnología y capacidad directiva para orientar decisiones de largo plazo. En un entorno caracterizado por alta competencia, digitalización y cambios rápidos en los mercados, las organizaciones necesitan utilizar los datos no solamente para describir resultados, sino también para identificar oportunidades, anticipar riesgos y construir ventajas competitivas sostenibles.

El enfoque estratégico basado en datos puede representarse como:

Datos → Información → Conocimiento → Decisión → Estrategia

La diferencia principal respecto de una gestión tradicional radica en que las decisiones estratégicas se sustentan en evidencia, indicadores, modelos y escenarios.

Una organización verdaderamente orientada a datos no depende exclusivamente de reportes, sino que incorpora la analítica dentro de sus procesos de planificación, control, innovación y aprendizaje.

2. Concepto de estrategia basada en datos

La estrategia basada en datos consiste en utilizar información confiable y herramientas analíticas para formular, ejecutar y evaluar decisiones estratégicas.

Puede expresarse como:

Estrategia basada en datos = Datos + Analítica + Tecnología + Gestión

Su aplicación permite responder preguntas como:

¿En qué mercados debería competir la empresa?

¿Qué clientes generan mayor valor?

¿Qué productos deberían priorizarse?

¿Qué riesgos podrían afectar el negocio?

¿Qué procesos requieren transformación?

3. Los datos como activo estratégico

Los datos pueden considerarse un activo empresarial cuando poseen características como:

- calidad;
- disponibilidad;
- confiabilidad;
- seguridad;
- relevancia;
- capacidad de reutilización.

Sin embargo, disponer de grandes cantidades de información no garantiza valor.

Puede representarse:

$$Datos \neq Valor$$

El valor aparece cuando:

$$Datos + Análisis + Acción = Resultado$$

Por ello, las organizaciones deben desarrollar mecanismos que conviertan datos en decisiones.

4. Ventaja competitiva basada en datos

Una organización puede generar ventaja competitiva cuando utiliza sus datos mejor que sus competidores.

Por ejemplo, puede:

- anticipar demanda;
- personalizar ofertas;
- reducir costos;
- detectar riesgos;
- mejorar experiencias;
- optimizar recursos.

La ventaja puede representarse:

$$Información \rightarrow Insight \rightarrow Acción superior \rightarrow Ventaja$$

La tecnología por sí sola puede ser fácilmente replicada. La verdadera diferencia se encuentra en la forma en que la organización integra datos, procesos y conocimiento.

5. Madurez analítica empresarial

Las organizaciones presentan diferentes niveles de madurez.

Nivel 1. Gestión intuitiva

Las decisiones dependen principalmente de experiencia y percepción.

Nivel 2. Gestión descriptiva

Se utilizan reportes e indicadores.

Nivel 3. Gestión diagnóstica

Se analizan causas.

Nivel 4. Gestión predictiva

Se utilizan modelos.

Nivel 5. Gestión prescriptiva

Se recomiendan acciones.

Nivel 6. Gestión inteligente

Los sistemas incorporan IA y automatización.

Puede representarse:

Intuición → Medición → Análisis → Predicción → Optimización → IA

6. Diagnóstico de madurez

Una organización puede evaluar dimensiones como:

Dimensión	Nivel
Calidad de datos	3
Tecnología	4
Analítica	3
Cultura	2
Gobierno	2
Talento	3

Si se utiliza una escala de 1 a 5:

$$\text{Madurez} = \frac{3 + 4 + 3 + 2 + 2 + 3}{6}$$
$$\text{Madurez} = 2.83$$

El resultado indicaría un nivel intermedio que requiere fortalecimiento.

7. Cultura data-driven

Una cultura data-driven implica que los datos formen parte habitual de las decisiones.

Sus características incluyen:

- uso frecuente de indicadores;
- cuestionamiento de supuestos;
- experimentación;
- transparencia;
- aprendizaje;
- responsabilidad.

Puede expresarse:

$$\text{Cultura data – driven} = \text{Datos} + \text{Personas} + \text{Hábitos}$$

No depende exclusivamente del área tecnológica.

8. Decisiones basadas en evidencia

Una decisión estratégica debería integrar:

$$\text{Experiencia} + \text{Datos} + \text{Contexto}$$

La experiencia gerencial continúa siendo importante, pero debe complementarse con evidencia.

Por ejemplo:

“Creemos que el producto A crecerá”.

puede transformarse en:

“Los datos muestran una tendencia de crecimiento del 18 %, una mayor frecuencia de compra y una probabilidad elevada de expansión”.

La segunda decisión posee mayor soporte analítico.


9. Planeación estratégica basada en datos

El proceso puede estructurarse:

Diagnóstico



Objetivos



Esto permite conectar la estrategia con resultados medibles.

10. Objetivos e indicadores

Un objetivo debe traducirse en indicadores.

Por ejemplo:

Objetivo

Incrementar participación de mercado.

Indicador

$$Participación = \frac{Ventas\ empresa}{Ventas\ mercado} \times 100$$

Si:

$$Ventas\ empresa = 2.000.000$$

y:

$$Mercado = 20.000.000$$

entonces:

$$Participación = 10\%$$

11. KPI estratégicos

Los KPI permiten monitorear objetivos prioritarios.

Ejemplos:

Financiero

Margen

Comercial

Conversión

Cliente

Retención

Operaciones

OTD

Ambiental

Intensidad energética

El reto consiste en evitar demasiados indicadores.

12. KPI y estrategia

Un KPI debe responder a:

Objetivo → Indicador → Meta → Acción

Por ejemplo:

Objetivo: Mejorar retención

↓

KPI: Churn

↓

Meta: < 8%

↓

Acción: Programa de fidelización

Esto conecta medición y ejecución.

13. OKR y datos

Los **Objectives and Key Results** pueden complementar los KPI.

Ejemplo:

Objetivo

Mejorar la experiencia digital.

Resultados clave

Conversión: 5% → 7%

Abandono: 70% → 55%

Satisfacción: 4.1 → 4.5

Los datos permiten verificar objetivamente el avance.

14. Balanced Scorecard

El Balanced Scorecard puede integrar información estratégica desde cuatro perspectivas:

- financiera;
- clientes;
- procesos;
- aprendizaje.

Puede expresarse:

Estrategia



Objetivos



Indicadores



Metas



Iniciativas

La analítica puede mejorar el monitoreo de cada perspectiva.

15. Portafolio de iniciativas analíticas

Las organizaciones pueden desarrollar múltiples proyectos:

- predicción de ventas;
- churn;
- fraude;
- inventarios;
- mantenimiento;
- marketing;
- sostenibilidad.

Sin embargo, no todos deben ejecutarse simultáneamente.

Puede priorizarse mediante:

$$\text{Prioridad} = \text{Impacto} \times \text{Factibilidad}$$

16. Matriz de priorización

Ejemplo:

Proyecto	Impacto	Factibilidad	Prioridad
Churn	5	4	20
Demanda	5	5	25
Fraude	4	3	12
ESG	3	4	12

El proyecto con mayor puntuación podría recibir prioridad.

17. Valor empresarial de la analítica

El éxito de un proyecto no debería medirse únicamente por:

Accuracy

También debe evaluarse:

Valor empresarial

Por ejemplo, un modelo puede aumentar la precisión de predicción solo 2 %, pero generar una reducción importante de pérdidas.

Por ello:

$$\acute{E}xito = Desempe\tilde{n}o\ anal\acute{i}tico + Impacto\ empresarial$$

18. Retorno de inversión analítica

Puede calcularse:

$$ROI = \frac{Beneficio - Costo}{Costo} \times 100$$

Supóngase:

$$\begin{aligned} Costo &= \$50000 \\ Beneficio &= \$125000 \end{aligned}$$

Entonces:

$$\begin{aligned} ROI &= \frac{125000 - 50000}{50000} \times 100 \\ ROI &= 150\% \end{aligned}$$

19. Estrategia de datos

Una estrategia de datos establece cómo la organización:

- recopila;
- almacena;
- comparte;
- protege;
- analiza;
- utiliza información.

Puede estructurarse:

$$Fuentes \rightarrow Arquitectura \rightarrow Gobierno \rightarrow Anal\acute{i}tica \rightarrow Valor$$

Debe estar alineada con la estrategia empresarial.

20. Arquitectura tecnológica

Una arquitectura moderna puede integrar:

ERP + CRM + IoT + Web



Data Warehouse/Lake



BI + Machine Learning



Decisiones

El objetivo es evitar sistemas aislados.

21. Gobierno de datos

El gobierno define:

- propietarios;
- estándares;
- acceso;
- calidad;
- privacidad;
- seguridad.

Puede representarse:

Gobierno = Roles + Reglas + Controles

Sin gobierno, diferentes áreas pueden producir cifras contradictorias.

22. Calidad de datos

Puede evaluarse mediante dimensiones como:

- exactitud;
- integridad;
- consistencia;
- actualidad;
- unicidad.

Por ejemplo:

$$Calidad = \frac{Registros\ válidos}{Registros\ totales} \times 100$$

Si:

9500

de:

10000

son válidos:

$$Calidad = 95\%$$

23. Data literacy

La alfabetización de datos representa la capacidad para leer, interpretar, cuestionar y utilizar información.

Una organización madura requiere que sus colaboradores comprendan:

- indicadores;
- gráficos;
- probabilidades;
- modelos;
- limitaciones.

No todos deben ser científicos de datos, pero sí necesitan comprender información básica.

24. Talento analítico

La estrategia requiere perfiles complementarios:

- analistas;
- científicos de datos;
- ingenieros;
- especialistas de negocio;
- directivos.

Puede expresarse:

$$\textit{Equipo efectivo} = \textit{Tecnología} + \textit{Analítica} + \textit{Conocimiento empresarial}$$

La colaboración interdisciplinaria resulta esencial.

25. Centro de excelencia analítica

Algunas organizaciones pueden crear un **Analytics Center of Excellence**.

Sus funciones pueden incluir:

- estándares;
- metodología;
- capacitación;
- gobierno;
- proyectos;
- buenas prácticas.

Esto evita que cada departamento desarrolle soluciones aisladas.

26. Experimentación empresarial

Una cultura analítica promueve pruebas controladas.

Por ejemplo:

Hipótesis

Una nueva promoción incrementará ventas.

Prueba

Grupo A recibe promoción.

Grupo B no recibe.

Resultado

$$\textit{Conversion}_A = 8\%$$

$$\textit{Conversion}_B = 6\%$$

Luego se analiza significancia estadística y efecto económico.

27. A/B testing estratégico

La experimentación reduce decisiones basadas únicamente en opiniones.

El proceso puede representarse:

Hipótesis → Experimento → Datos → Resultado → Decisión

Esto es útil en:

- marketing;
- precios;
- plataformas digitales;
- servicios.

28. Analítica predictiva y estrategia

La predicción permite anticipar escenarios.

Ejemplos:

Ventas_{futuras}
Riesgo
Demanda
Churn

La estrategia puede entonces pasar de reactiva a anticipativa.

29. Analítica prescriptiva

La analítica prescriptiva busca recomendar qué acción adoptar.

Puede representarse:

Predicción + Restricciones + Objetivo

↓

Recomendación

Por ejemplo:

Maximizar utilidad

sujeto a:

Presupuesto
Inventario
Capacidad

30. Inteligencia artificial en estrategia

La IA puede apoyar:

- predicciones;
- recomendaciones;
- escenarios;
- automatización;
- análisis de texto;
- detección de riesgos.

Sin embargo:

IA ≠ Estrategia

La IA es una herramienta. La organización todavía debe definir objetivos, prioridades y criterios.

31. Inteligencia artificial generativa

La IA generativa puede apoyar:

- análisis documental;
- generación de reportes;
- síntesis;
- interacción con datos;
- exploración de escenarios.

Por ejemplo, un directivo podría solicitar:

“Resume las principales causas de reducción de ventas y compara con el trimestre anterior”.

El sistema podría combinar lenguaje natural y datos empresariales.

32. Automatización de decisiones

Algunas decisiones repetitivas pueden automatizarse.

Ejemplo:

Stock < ROP

↓

Generar orden

Otro ejemplo:

$P(\text{Churn}) > 0.85$



Activar campaña

La automatización debe incluir reglas de supervisión.

33. Human-in-the-loop

No todas las decisiones deberían automatizarse completamente.

El enfoque **human-in-the-loop** combina:

IA + Supervisión humana

Esto resulta especialmente importante en:

- crédito;
- empleo;
- riesgos;
- decisiones estratégicas.

La responsabilidad final no desaparece por utilizar algoritmos.

34. IA responsable

Una estrategia de inteligencia artificial debe considerar:

- transparencia;
- privacidad;
- seguridad;
- equidad;
- trazabilidad.

Puede representarse:

IA responsable = Desempeño + Gobernanza + Ética + Control

El NIST AI Risk Management Framework propone gestionar riesgos asociados con sistemas de inteligencia artificial durante todo su ciclo de vida.

35. Riesgo estratégico

Los datos también permiten identificar riesgos relacionados con:

- competencia;
- tecnología;
- regulación;
- mercado;
- reputación;
- clima.

Puede utilizarse:

$$Riesgo = Probabilidad \times Impacto$$

y priorizar acciones según criticidad.

36. Análisis de escenarios estratégicos

Puede evaluarse:

Escenario optimista

Demanda + 20%

Base

Demanda estable

Pesimista

Demanda – 20%

Luego se analiza el impacto sobre:

- ingresos;
- costos;
- capacidad;
- caja;
- inventarios.

Esto fortalece la resiliencia.

37. Estrategia de sostenibilidad basada en datos

Los objetivos de sostenibilidad también pueden integrarse.

Ejemplo:

Objetivo: Reducir energía 15%



KPI: kWh/unidad



Datos



Dashboard



Acción

Esto conecta sostenibilidad y desempeño empresarial.

38. Estrategia centrada en el cliente

La analítica permite comprender:

- necesidades;
- comportamiento;
- valor;
- satisfacción;
- riesgo de abandono.

Puede representarse:

Datos del cliente → Segmentación → Personalización → Experiencia → Lealtad

El cliente se convierte así en una fuente continua de información estratégica.

39. Estrategia comercial basada en datos

Puede integrar:

Ventas + Marketing + Clientes + Competencia

para decidir:

- segmentos prioritarios;

- canales;
- precios;
- productos;
- promociones.

La estrategia comercial evoluciona desde campañas generales hacia intervenciones cada vez más específicas.

40. Estrategia operacional basada en datos

La organización puede optimizar:

- inventarios;
- producción;
- logística;
- capacidad;
- mantenimiento.

Puede expresarse:

Demanda prevista → Capacidad → Inventario → Distribución

Esto permite alinear operaciones con el mercado.

41. Estrategia financiera basada en datos

Puede utilizar:

- pronósticos;
- riesgo;
- escenarios;
- liquidez;
- rentabilidad.

Por ejemplo:

Flujo futuro → Necesidad financiera → Decisión

La analítica mejora la capacidad de anticipar necesidades de capital.

42. Dashboard estratégico

Un dashboard ejecutivo podría incluir:

Dimensión	KPI	Resultado	Meta
Financiera	Margen	18 %	20 %
Comercial	Crecimiento	12 %	15 %
Cliente	Retención	89 %	92 %
Operaciones	OTD	91 %	95 %
Ambiental	Energía	14 kWh/u	13
Personas	Rotación	9 %	<8 %

La gerencia puede identificar rápidamente brechas estratégicas.

43. Alertas estratégicas

Los sistemas modernos pueden generar alertas.

Por ejemplo:

$$\textit{Margen} < 15\%$$



Alerta

Otro caso:

$$\textit{Churn} > 12\%$$



Alerta

Esto permite actuar antes de que el problema se agrave.

44. Caso aplicado

Considérese una empresa comercial con los siguientes resultados:

Indicador	Actual	Meta
Ventas	\$2.000.000	\$2.200.000
Margen	17 %	20 %
Retención	88 %	92 %

OTD	90 %	95 %
CAC	\$45	\$40

La empresa presenta varias brechas.

45. Diagnóstico

Puede calcularse:

Cumplimiento de ventas

$$CV = \frac{2000000}{2200000} \times 100$$

$$CV = 90.91\%$$

La empresa alcanza aproximadamente el 91 % de su meta.

46. Priorización

Supóngase la siguiente matriz:

Problema	Impacto	Urgencia	Puntaje
Margen	5	5	25
Retención	5	4	20
OTD	4	4	16
CAC	3	3	9

La empresa debería priorizar inicialmente la reducción de la brecha de margen.

47. Modelo predictivo estratégico

Puede utilizarse:

$$\text{Margen} = f(P, r, e, \text{cioCostoVolumenDescuento})$$

Si el análisis muestra que descuentos excesivos explican parte de la reducción del margen, la empresa puede revisar su política comercial.

48. Escenario de mejora

Supóngase que la empresa:

- reduce descuentos;
- optimiza inventarios;

- mejora retención;
- reduce costos logísticos.

El modelo proyecta:

$$\begin{aligned} \text{Margen} &= 20.5\% \\ \text{Ventas} &= \$2.250.000 \end{aligned}$$

La analítica permite evaluar la estrategia antes de implementarla plenamente.

49. Roadmap de transformación data-driven

Puede estructurarse en cinco etapas.

Etapas 1

Diagnóstico.

Etapas 2

Integración de datos.

Etapas 3

Business Intelligence.

Etapas 4

Analítica predictiva.

Etapas 5

IA y automatización.

Puede representarse:

$$\text{Diagnóstico} \rightarrow \text{Integración} \rightarrow \text{BI} \rightarrow \text{ML} \rightarrow \text{IA}$$

50. Gestión del cambio

La transformación basada en datos implica cambios culturales.

Entre las principales barreras se encuentran:

- resistencia;
- temor;
- falta de competencias;
- estructuras tradicionales.

La organización debe combinar:

$$\text{Tecnología} + \text{Capacitación} + \text{Liderazgo} + \text{Comunicación}$$

El cambio tecnológico sin cambio cultural suele generar resultados limitados.

51. Liderazgo basado en datos

Los directivos desempeñan un papel fundamental.

Deben:

- promover uso de evidencia;
- solicitar indicadores;
- cuestionar supuestos;
- apoyar experimentación;
- aceptar resultados contrarios a expectativas.

Una cultura analítica requiere liderazgo visible.

52. Limitaciones de la estrategia basada en datos

Entre sus principales limitaciones están:

- mala calidad de datos;
- interpretación incorrecta;
- exceso de indicadores;
- dependencia tecnológica;
- sesgo algorítmico;
- resistencia organizacional.

Asimismo:

Datos históricos ≠ Futuro garantizado

Los datos deben complementarse con conocimiento del contexto.


53. Tendencias futuras

Entre las tendencias más relevantes se encuentran:

- IA generativa;
- analítica en tiempo real;
- agentes inteligentes;
- automatización;

- data products;
- MLOps;
- inteligencia aumentada;
- sistemas autónomos de decisión.

La evolución puede representarse:



54. Conclusiones

La estrategia empresarial basada en datos representa la etapa de integración de los diferentes componentes de la analítica empresarial. No consiste simplemente en utilizar software, desarrollar dashboards o implementar algoritmos, sino en convertir los datos en un recurso que mejore sistemáticamente la formulación y ejecución de decisiones.

Las organizaciones pueden evolucionar desde modelos intuitivos hacia modelos descriptivos, predictivos y prescriptivos. Sin embargo, este proceso requiere infraestructura tecnológica, gobierno de datos, talento analítico y una cultura organizacional orientada a evidencia.

El valor estratégico puede expresarse como:

$$\text{Datos} + \text{Analítica} + \text{Personas} + \text{Estrategia} = \text{Valor empresarial}$$

Los modelos predictivos permiten anticipar eventos, Business Intelligence facilita el seguimiento de indicadores y la inteligencia artificial amplía las posibilidades de automatización y apoyo a decisiones.

No obstante, una estrategia basada en datos debe mantener principios de transparencia, seguridad, privacidad y responsabilidad.

La transformación puede resumirse:

Dato → Insight → Decisión → Acción → Resultado → Aprendizaje

Este ciclo convierte la analítica en una capacidad organizacional permanente.

En consecuencia, la principal ventaja de una organización basada en datos no reside simplemente en disponer de más información, sino en desarrollar la capacidad de convertir esa información en **decisiones más rápidas, precisas, responsables y estratégicamente relevantes**.

Referencias bibliográficas

Davenport, T. H., & Bean, R. (2023). *All-in on AI: How smart companies win big with artificial intelligence*. Harvard Business Review Press.

James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). *An introduction to statistical learning: With applications in Python*. Springer.

Laudon, K. C., Laudon, J. P., & Traver, C. G. (2025). *Management information systems: Managing the digital firm* (18th ed.). Pearson.

National Institute of Standards and Technology. (2023). *Artificial intelligence risk management framework (AI RMF 1.0) (NIST AI 100-1)*. U.S. Department of Commerce.

Sharda, R., Delen, D., & Turban, E. (2024). *Business intelligence, analytics, data science, and AI* (5th ed.). Pearson.

Shmueli, G., Bruce, P. C., Gedeck, P., & Patel, N. R. (2023). *Data mining for business analytics: Concepts, techniques, and applications in Python*. Wiley.