

PNAV

PROGRAMA NACIONAL
DE ALGORITMOS
VERDES

Guía de buenas prácticas

Casos de Uso



Financiado por
la Unión Europea
NextGenerationEU



España | digital ²⁰²⁶

accenture

Financiado por la Unión Europea - NextGenerationEU. Sin embargo, los puntos de vista y las opiniones expresadas son únicamente los del autor o autores y no reflejan necesariamente los de la Unión Europea o la Comisión Europea. Ni la Unión Europea ni la Comisión Europea pueden ser consideradas responsables de las mismas

Índice

Antes de empezar	5
1. ¿Cuándo tiene sentido aplicar la IA?	6
1.1. Generación de impacto social y ambiental significativo	6
1.2. Potencial para frenar el cambio climático	6
1.3. Enfoque limitado, escalable y orientado a resultados	7
1.4. Evaluación consciente de la huella ambiental	7
1.5. Marco de decisión responsable basado en criterios ESG	7
2. Riesgos de aplicarla incorrectamente	7
2.1. Consumo intensivo de recursos sin retorno proporcional	7
2.2. Incremento de la huella ambiental	8
2.3. Sesgos en los resultados y falta de equidad	8
2.4. Vulnerabilidades en privacidad y seguridad de los datos	8
2.5. Escasa escalabilidad y riesgo de obsolescencia	8
2.6. Déficit de legitimidad social y aceptación pública	8
Proceso de definición de casos de uso	9
1. Identificar oportunidades	9
1.1. Análisis de procesos internos	9
1.2. Análisis de las necesidades de clientes	10
1.3. Actores implicados y partes interesadas	11
1.4. Generación de ideas	12
2. Aterrizar el caso de uso	13
2.1. Elementos esenciales al aterrizar el caso de uso	14
2.2. Definir el objetivo y el ámbito de aplicación	15
2.3. Amenazas y vulnerabilidades	16
2.4. Retos y problemas del caso de uso	18
2.5. Consideraciones de fiabilidad	19
2.6. KPIs para medir el éxito	21
3. Selección de tecnologías aplicables	24

3.1. Modelos preentrenados y fundacionales	24
3.2. Métodos de reutilización y adaptación de modelos	25
3.3. Estrategias de despliegue sostenible	25
3.4. IA para optimizar IA	26
4. Análisis de impacto	26
4.1. Impacto medioambiental.....	27
4.2. Impacto social	29
4.3. Impacto económico	31
5. Evaluación de la viabilidad	33
5.1. Aspectos legales y éticos.....	34
5.2. Alineación con la estrategia empresarial.....	34
5.3. Criterios tecnológicos	35
5.4. Criterios operativos.....	36
5.5. Relación coste-beneficio	37
6. Priorización y selección	38
Bibliografía	42

Antes de empezar

La inteligencia artificial se ha convertido en un elemento transformador en la actividad de empresas, instituciones y administraciones públicas. Su capacidad para procesar grandes volúmenes de información, generar patrones de predicción y automatizar procesos abre oportunidades inéditas para incrementar la eficiencia, mejorar la toma de decisiones y abordar retos de gran complejidad. Sin embargo, el entusiasmo que suscita no debe llevar a confundir el potencial de la tecnología con una solución universal aplicable en cualquier contexto.

Antes de adentrarse en el detalle de las fases y buenas prácticas que conforman esta guía, conviene enmarcar el punto de partida en una serie de consideraciones generales que ayudan a situar al lector en la perspectiva adecuada:

La IA como medio, no como fin

La IA debe entenderse como una herramienta que, en determinadas circunstancias, aporta un valor diferencial frente a otros enfoques. Su aplicación carece de sentido si no responde a una necesidad concreta, definida con claridad, y si no se evalúa previamente si otras soluciones menos complejas, más económicas y de menor impacto ambiental podrían resolver el mismo problema.

El papel central del dato

El rendimiento de cualquier sistema de inteligencia artificial depende en gran medida de la disponibilidad y calidad de los datos. Modelos basados en información insuficiente, incompleta o sesgada generan resultados poco fiables y con un alto riesgo de error. Por ello, antes de iniciar cualquier iniciativa, es imprescindible contar con una estrategia de datos que asegure su gobernanza, integridad y representatividad.

La sostenibilidad como principio rector

El desarrollo y operación de sistemas de IA implica consumo energético, necesidad de infraestructuras tecnológicas y, en consecuencia, un impacto ambiental tangible. Desde la fase inicial, debe existir un compromiso explícito con la eficiencia en el uso de recursos y la mitigación de huella ambiental. Este criterio no solo responde a consideraciones éticas o regulatorias, sino que también contribuye a reforzar la legitimidad de los proyectos ante la sociedad.

La importancia de la gobernanza y la confianza

La adopción de la IA exige un marco robusto de gobernanza que asegure la transparencia de los modelos, la protección de la privacidad y la ciberseguridad de los sistemas. La ausencia de estos

elementos incrementa el riesgo de incidentes, pérdida de confianza y sanciones regulatorias. Antes de iniciar un proyecto, debe verificarse que existen políticas y mecanismos de supervisión adecuados para garantizar un desarrollo responsable.

El valor debe ser tangible y medible

No basta con demostrar viabilidad técnica. Los proyectos de IA deben justificarse por su capacidad de generar un retorno claro, ya sea en términos económicos, de eficiencia operativa o de impacto social y ambiental. Esta premisa resulta esencial para asegurar la sostenibilidad de las inversiones y para priorizar aquellos casos de uso con mayor potencial transformador.

1. ¿Cuándo tiene sentido aplicar la IA?

La inteligencia artificial (IA) no debe ser vista como una panacea tecnológica, sino como una herramienta estratégica que merece aplicarse únicamente cuando genere un valor diferencial tangible y sostenible, y lo haga de forma eficiente en el uso de los recursos.

1.1. Generación de impacto social y ambiental significativo

La IA debe desplegarse cuando contribuya de manera concreta al bienestar social o a la preservación del entorno. Su aplicación es especialmente válida si está alineada con retos globales reconocidos (como los Objetivos de Desarrollo Sostenible) y si existen casos de uso reales que ya estaban en marcha o en piloto, demostrando su capacidad de transformar sectores críticos como respuesta ante crisis, inclusión o desarrollo educativo.

A la vez, resulta clave considerar no solo el impacto positivo que la IA puede generar en otros sectores (green by AI), sino también la sostenibilidad de la propia tecnología (green in AI). Esto implica que los modelos, infraestructuras y procesos asociados al desarrollo y despliegue de IA se diseñen con eficiencia energética, minimización de huella ambiental y uso responsable de recursos, garantizando así que la innovación no compromete los objetivos de sostenibilidad que persigue.

1.2. Potencial para frenar el cambio climático

La IA cobra sentido cuando puede apoyar la acción climática de forma escalable. Cuando identifica y optimiza intervenciones que pueden reducir de manera medible las emisiones de gases de efecto invernadero —sinergizando con planes de mitigación y resiliencia—, su uso deja de ser solo una inversión tecnológica para convertirse en un motor para alcanzar metas sostenibles a nivel global.

1.3. Enfoque limitado, escalable y orientado a resultados

No se trata de multiplicar proyectos sin foco, sino de centrarse en un número limitado de casos de uso con alto potencial de impacto y retorno claro. Las organizaciones que logran esto integran la IA en procesos centrales, transforman flujos de trabajo, escalan soluciones comprobadas y miden rigurosamente tanto beneficios como costes.

1.4. Evaluación consciente de la huella ambiental

Incluso las soluciones de IA con alto impacto pueden tener costes ambientales importantes. El entrenamiento de modelos de gran escala consume una cantidad significativa de energía y agua, y puede generar más emisiones que las de un coche medio durante toda su vida útil. Aplicar IA con sentido también implica medir y mitigar estas externalidades, considerando su huella total.

1.5. Marco de decisión responsable basado en criterios ESG

La sostenibilidad real de un proyecto de IA no se evalúa solo por su impacto funcional, sino también por su alineamiento con principios ambientales, sociales y de gobernanza. Contar con marcos estructurados que permitan evaluar la materialidad de una aplicación —su impacto ambiental o social—, la gobernanza responsable que la acompaña, y los riesgos éticos asociados, es esencial para decidir con criterio cuándo aplicar IA.

2. Riesgos de aplicarla incorrectamente

El desarrollo de soluciones de inteligencia artificial conlleva una serie de riesgos que deben ser identificados y gestionados desde las fases iniciales de cada proyecto. Una planificación inadecuada o un despliegue sin mecanismos de control puede derivar en efectos contrarios a los objetivos perseguidos, generando impactos negativos tanto en el ámbito organizativo como en el ambiental y social.

2.1. Consumo intensivo de recursos sin retorno proporcional

El entrenamiento y operación de modelos de gran escala requieren infraestructuras de cómputo con un elevado consumo energético y de agua para refrigeración. Cuando estos esfuerzos no se traducen en beneficios medibles o escalables, el resultado es un uso ineficiente de recursos económicos y materiales. La ausencia de un análisis previo de coste-beneficio puede conducir a inversiones significativas en capacidades técnicas que no generan valor añadido ni retorno suficiente para la organización.

2.2. Incremento de la huella ambiental

La huella de carbono y el impacto ambiental asociados al ciclo de vida de los modelos de IA constituyen un riesgo relevante si no se gestionan de manera adecuada. Factores como la demanda energética de los centros de datos, la necesidad de infraestructuras de refrigeración y la generación de residuos electrónicos incrementan la presión sobre el medioambiente. Un desarrollo incorrecto, sin medidas de eficiencia energética o planes de mitigación, puede contradecir compromisos institucionales de sostenibilidad.

2.3. Sesgos en los resultados y falta de equidad

La calidad de los resultados de la IA depende en gran medida de la representatividad y fiabilidad de los datos de entrenamiento. Cuando estos contienen sesgos, los algoritmos tienden a reproducirlos o amplificarlos, generando resultados que pueden ser discriminatorios o injustos para determinados colectivos. La ausencia de mecanismos de auditoría y validación genera riesgos legales, reputacionales y éticos, especialmente en sectores donde la equidad en la toma de decisiones es fundamental.

2.4. Vulnerabilidades en privacidad y seguridad de los datos

Los modelos de IA suelen basarse en grandes volúmenes de datos, incluidos en ocasiones datos sensibles. Si no se establecen controles de gobernanza y ciberseguridad adecuados, aumenta la exposición a incidentes como filtraciones, accesos no autorizados o manipulación de la información. Estos fallos no solo comprometen la seguridad de los sistemas, sino que también exponen a las organizaciones a sanciones regulatorias derivadas del incumplimiento de normativas de protección de datos.

2.5. Escasa escalabilidad y riesgo de obsolescencia

La falta de una visión de medio y largo plazo en el diseño de modelos de IA puede dar lugar a desarrollos aislados, con bajo nivel de reutilización y limitada capacidad de adaptación a nuevos contextos. Esto obliga a realizar inversiones adicionales en proyectos paralelos y reduce la eficiencia global de la estrategia digital. Además, la rápida evolución tecnológica incrementa el riesgo de obsolescencia temprana de soluciones que no se diseñan con criterios de flexibilidad y actualización continua.

2.6. Déficit de legitimidad social y aceptación pública

El uso de la inteligencia artificial está cada vez más sometido al escrutinio de la opinión pública, reguladores y grupos de interés. La falta de transparencia en los objetivos, en los impactos ambientales o en los mecanismos de control puede generar desconfianza y cuestionamientos sobre la legitimidad de los proyectos. Esta pérdida de confianza afecta tanto a la reputación institucional como a la capacidad de las organizaciones de mantener su licencia social para operar, independientemente de los resultados técnicos obtenidos.

Proceso de definición de casos de uso

3. Identificar oportunidades

3.1. Análisis de procesos internos

Resulta imprescindible realizar un análisis riguroso de los procesos internos de la organización. Este paso no solo asegura que las iniciativas futuras se construyan sobre bases sólidas, trazables y alineadas con las exigencias regulatorias y de sostenibilidad actuales, sino que también permite **detectar ineficiencias, cuellos de botella y áreas de mejora donde la IA puede aportar un valor diferencial**.

El análisis debe realizarse en dos niveles complementarios:

- **Operativo:** identificación de los flujos de datos, consumo de recursos y puntos críticos en la ejecución de procesos.
- **Estratégico:** conexión de esas ineficiencias con objetivos de negocio (reducción de costes, sostenibilidad, mejora del servicio, diferenciación competitiva).

De este cruce se desprenden los **casos de uso potenciales**, priorizados según su impacto y viabilidad.

3.1.1. Diagnóstico de procesos y flujos de datos

Mapear los procesos de negocio clave mediante entrevistas, talleres y herramientas de modelado de procesos. Identificar los puntos donde se concentran mayores consumos de recursos, emisiones, tiempos o errores. Estos indicadores se convierten en **candidatos para casos de uso de IA**, al evidenciar espacios de mejora medibles.

3.1.2. Gobernanza y gestión de riesgos

Analizar qué estructuras de control y supervisión ya existen (compliance, calidad, auditoría) y cómo pueden integrarse con iniciativas de IA. Su ausencia o debilidad señala **oportunidades de reforzar la gobernanza con herramientas de IA**, por ejemplo, para monitoreo automatizado o sistemas de alerta temprana.

3.1.3. Procesos de reporte y transparencia

Evaluar si los procesos internos actuales generan datos trazables y auditables. Una falta de calidad en los datos puede traducirse en **un caso de uso centrado en mejorar la consolidación y fiabilidad de la información corporativa**, habilitando después proyectos de mayor impacto.

3.1.4. *Infraestructura y eficiencia energética*

Inventariar centros de datos, hardware y software, midiendo consumos y huella ambiental. Este ejercicio revela **oportunidades para introducir IA en la optimización energética, mantenimiento predictivo o gestión dinámica de cargas.**

3.1.5. *Fiabilidad y ética en los procesos*

Analizar dónde existen riesgos de sesgo, problemas de privacidad o brechas de seguridad. Estas áreas representan tanto riesgos como **espacios donde la IA ética y responsable puede fortalecer la confianza y habilitar nuevos servicios.**

3.2. **Análisis de las necesidades de clientes**

La definición de casos de uso de inteligencia artificial en el ámbito de la sostenibilidad requiere comenzar por una comprensión profunda de las necesidades reales de los clientes. Este análisis asegura que los proyectos se centren en resolver problemas concretos y generar un valor que combine eficiencia, diferenciación estratégica y compromiso sostenible.

3.2.1. *Comprensión de las expectativas del cliente*

El punto de partida es entender cómo perciben los clientes los productos, servicios y experiencias que la organización ofrece. Identificar sus dolores (pains), expectativas y oportunidades de mejora permite orientar la IA hacia áreas donde puede aportar un cambio tangible. Las herramientas de *customer journey mapping* y de análisis de datos de comportamiento son fundamentales para identificar puntos de fricción y diseñar experiencias más fluidas, personalizadas y sostenibles.

3.2.2. *Oportunidades de negocio y ventaja competitiva*

El análisis de necesidades debe ir más allá de la eficiencia inmediata y situarse en el plano estratégico. Cada caso de uso de IA debe evaluarse en función de su potencial para crear ventaja competitiva sostenible. Esto implica identificar cómo la IA puede abrir nuevos nichos de mercado, mejorar la propuesta de valor frente a la competencia o fortalecer la relación con clientes mediante productos y servicios responsables. Una visión estratégica permite seleccionar casos de uso que, además de aportar eficiencia, refuercen el posicionamiento de la organización en el mercado.

3.2.3. *Priorización de necesidades con criterios de sostenibilidad*

No todas las necesidades detectadas deben abordarse de inmediato. La organización debe priorizar aquellas que generan mayor impacto positivo en términos ambientales, sociales y económicos. Aplicar criterios de doble materialidad —cómo afecta la organización al entorno y cómo los riesgos del entorno afectan a la organización— permite distinguir los casos de uso con más relevancia estratégica. Al mismo tiempo, la transparencia y la ética en el diseño de soluciones refuerzan la confianza del cliente, que se convierte en un activo competitivo.

3.2.4. Cultura y gestión del cambio centrada en el cliente

Finalmente, este análisis requiere un cambio cultural hacia un enfoque auténticamente customer-centric. Ello supone adoptar una mentalidad donde los datos, la sostenibilidad y la innovación sean elementos estructurales de la estrategia. Los líderes deben impulsar una cultura de co-creación con clientes, fomentar la colaboración multidisciplinar y asegurar que las decisiones tecnológicas reflejan tanto los intereses empresariales como las expectativas sociales.

3.3. Actores implicados y partes interesadas

El éxito en la definición de casos de uso de inteligencia artificial orientados a la sostenibilidad depende no solo de los procesos internos y de las necesidades del cliente, sino también de la identificación adecuada de los **actores implicados** y de las **partes interesadas (stakeholders)**. Este análisis permite comprender quiénes intervienen directamente en el diseño, validación y despliegue de los casos de uso, así como quiénes influyen o se ven afectados por ellos.

3.3.1. Stakeholders internos

En el ámbito organizativo es útil distinguir entre tres niveles de implicación:

- **Capa operativa:** conformada por los equipos que trabajan en el día a día del caso de uso. Incluye científicos e ingenieros de datos, equipos de MLOps, responsables de sostenibilidad operativa y analistas de negocio. Son quienes ejecutan y mantienen los sistemas de IA, garantizando la disponibilidad de datos y la eficiencia técnica.
- **Capa táctica:** integra a los responsables intermedios que convierten la estrategia en proyectos viables. Aquí destacan los responsables de áreas de negocio, ESG y compliance, así como los **validadores de IA** —equipos de auditoría de modelos, comités de ética o responsables de gobernanza responsable— que aseguran la calidad, robustez y conformidad normativa de las soluciones.
- **Capa estratégica:** compuesta por el comité de dirección, la alta dirección y, en su caso, figuras específicas como el Chief AI Officer. Son quienes garantizan que el caso de uso se alinee con la estrategia corporativa, la gestión de riesgos y la visión de sostenibilidad de la organización.

Foros internos. Además de los roles y órganos formales, muchas organizaciones refuerzan la participación y la coordinación a través de **foros internos**, concebidos como espacios de intercambio y deliberación. Estos foros permiten integrar perspectivas diversas y acelerar la madurez organizativa en IA y sostenibilidad. Algunos ejemplos son:

- **Foros técnicos de innovación y datos:** donde los equipos comparten avances, buenas prácticas y aprendizajes sobre el desarrollo y despliegue de casos de uso.

- **Foros de ética y responsabilidad en IA:** espacios donde empleados de distintas áreas (no solo de compliance) discuten dilemas éticos, sesgos y el impacto social de los algoritmos.
- **Foros de sostenibilidad aplicada a la IA:** orientados a evaluar colectivamente cómo los proyectos de IA contribuyen a los objetivos ESG y a identificar oportunidades de mejora.
- **Foros de usuarios internos:** comunidades de práctica que actúan como puente entre negocio, tecnología y áreas de impacto.

Estos foros no sustituyen a los comités formales, pero funcionan como mecanismos ágiles que fomentan la cultura organizativa en IA, aseguran una voz más plural en la toma de decisiones y refuerzan la legitimidad del modelo de gobernanza.

3.3.2. *Stakeholders externos: clientes y reguladores*

Además de los actores internos, es imprescindible identificar los stakeholders externos, distinguiendo entre dos tipos de relación:

- **Clientes y usuarios finales:** constituyen la principal fuente de necesidades y expectativas. Su retroalimentación permite validar la pertinencia de un caso de uso, evaluar la aceptación social y reforzar la confianza en la organización.
- **Reguladores:** marcan los marcos normativos y los límites de actuación. Incluyen a la Comisión Europea, autoridades nacionales y supervisores sectoriales que, mediante regulaciones como el AI Act, la CSRD o el GDPR, establecen obligaciones vinculantes que condicionan el diseño y la puesta en marcha de los casos de uso.

3.3.3. *Marco de gobernanza integral*

La integración de actores internos y externos crea un ecosistema de gobernanza que asegura que los casos de uso de IA en sostenibilidad se desarrollen de manera responsable, transparente y eficiente. Mientras los clientes definen expectativas y los reguladores fijan las reglas del juego, los equipos internos —desde la operación diaria hasta la dirección estratégica— deben coordinarse para garantizar que cada caso de uso se despliegue con rigor técnico, legitimidad ética y viabilidad a largo plazo.

3.4. **Generación de ideas**

La fase de generación de ideas constituye un punto de inflexión en el proceso de definición de casos de uso de inteligencia artificial orientados a la sostenibilidad. Tras haber analizado los procesos internos (1.1), identificado las necesidades de los clientes (1.2) y mapeado los actores implicados (1.3), el reto consiste en transformar esos insumos en propuestas concretas y evaluables. No se trata de promover una lluvia de ideas indiscriminada, sino de articular un

proceso estructurado, inclusivo y basado en evidencias, capaz de canalizar la creatividad hacia soluciones con impacto real en la organización (**mejora de procesos, eficiencia, sostenibilidad interna**), en la sociedad y en el entorno medioambiental.

De acuerdo con marcos reconocidos como el **Oslo Manual de la OCDE**, la innovación solo puede consolidarse cuando se combinan la exploración de nuevas oportunidades con la capacidad interna para desarrollarlas y escalarlas. A ello se suma la necesidad de alinear las ideas con el marco regulatorio europeo, especialmente el **AI Act** y las normativas vinculadas a la sostenibilidad (CSRD, Taxonomía Verde), que generan tanto obligaciones como oportunidades para las organizaciones.

3.4.1. Palancas de generación de ideas

Las ideas de calidad no surgen de manera aislada, sino que se activan a partir de una serie de **palancas** que sirven como detonantes y filtros iniciales de pertinencia:

Sostenibilidad como motor de innovación

La transición ecológica y social no es únicamente un desafío regulatorio, sino un catalizador de ideas. Tal y como destacan organismos como la **Agencia Europea de Medio Ambiente** y foros globales como el **World Economic Forum**, la IA puede convertirse en un habilitador clave para reducir la huella ambiental, mejorar la eficiencia de procesos y fomentar una economía inclusiva. Ejemplos de palancas en este sentido incluyen la medición de emisiones en tiempo real, la optimización energética mediante algoritmos avanzados o la creación de modelos predictivos para gestionar riesgos climáticos.

Capacidades internas de la organización

Las ideas más prometedoras emergen allí donde existe una base sólida de datos, competencias tecnológicas y cultura organizativa. El **Oslo Manual** subraya la importancia de vincular la generación de ideas con las capacidades internas, ya que la viabilidad a medio plazo depende de contar con talento especializado, infraestructuras digitales y procesos de gobernanza de datos consolidados. En este sentido, la organización debe ser consciente de sus fortalezas y limitaciones antes de apostar por determinadas líneas de ideación.

4. Aterrizar el caso de uso

La fase de aterrizaje constituye el momento en el que una idea preliminar se transforma en una iniciativa estructurada y susceptible de evaluación. Su objetivo no es únicamente dotar de concreción al caso de uso, sino garantizar que esta concreción se realiza bajo principios de gestión sólidos, con criterios estratégicos, tecnológicos, operativos y medioambientales claramente definidos.

En esta etapa se abordan cinco dimensiones esenciales, descritas a continuación.

4.1. Elementos esenciales al aterrizar el caso de uso

4.1.1. Definición del alcance

Aterrizar un caso de uso comienza con la delimitación precisa de su alcance. Esta delimitación debe responder a tres preguntas fundamentales:

- ¿Qué problema u oportunidad pretende resolver?
- ¿En qué procesos, áreas o unidades se aplicará?
- ¿Qué limitaciones y exclusiones se establecen desde el inicio?

Un alcance claro y consensuado evita la dispersión de esfuerzos y facilita la alineación de expectativas. La perspectiva medioambiental debe formar parte de esta definición, asegurando que desde el inicio se establecen límites en términos de impacto energético, eficiencia de infraestructura tecnológica y coherencia con los compromisos de sostenibilidad de la organización.

4.1.2. Diseño de un roadmap de desarrollo

El aterrizaje no supone el despliegue inmediato de una solución final, sino la construcción de un itinerario progresivo que facilite el aprendizaje, la adaptación y la validación temprana. El roadmap debe estructurarse en fases claras, con hitos intermedios que permitan evaluar la evolución del proyecto y decidir sobre su continuidad. En cada fase, los criterios de sostenibilidad deben actuar como checkpoints obligatorios que condicionen el avance hacia etapas posteriores.

4.1.3. Definición de entregables tangibles

Para dotar de seriedad al proceso, cada caso de uso debe expresarse en entregables concretos y verificables. Entre ellos se incluyen:

- Documento de caso de uso inicial (objetivo, alcance, criterios transversales).
- Diseño funcional preliminar.
- Evaluación de requisitos de datos, tecnología y capacidades organizativas.
- Informe preliminar de impactos, con un apartado específico sobre implicaciones medioambientales.

Estos entregables constituyen la base documental que garantiza trazabilidad y accountability en la toma de decisiones.

4.1.4. Definición de criterios de decisión (“go/no-go”)

Finalmente, el proceso de aterrizaje debe culminar en la definición de criterios claros para decidir sobre la continuidad o el escalado del caso de uso. Dichos criterios deben considerar:

- Su valor estratégico y grado de alineación con los objetivos de la organización.
- La viabilidad técnica, operativa y organizativa.
- La relación coste–beneficio preliminar.
- El cumplimiento de criterios mínimos en materia de sostenibilidad ambiental, cuya superación debe considerarse condición indispensable para el avance.

4.2. Definir el objetivo y el ámbito de aplicación

La definición clara del **objetivo** y el **ámbito de aplicación** constituye el punto de partida metodológico de cualquier caso de uso de inteligencia artificial en sostenibilidad. Esta fase permite traducir la visión estratégica en un marco operativo concreto, evitando desviaciones posteriores y garantizando la alineación con los compromisos corporativos y regulatorios.

4.2.1. *Objetivos: formulación estratégica y medible*

Los objetivos de un caso de uso deben plantearse como **logros alcanzados** y no como actividades en curso, siguiendo la lógica metodológica empleada por marcos institucionales. Una formulación clara facilita la rendición de cuentas y asegura que el impacto esperado sea evaluable. Los objetivos deben cumplir con criterios de **especificidad, medibilidad, alcanzabilidad, relevancia y temporalidad (SMART)**, integrando desde el inicio factores ambientales, sociales y de gobernanza.

4.2.2. *Ámbito de aplicación: delimitación y control*

El **ámbito de aplicación** establece las fronteras del caso de uso, definiendo lo que se incluye y lo que explícitamente queda fuera. Esto supone elaborar un “marco de alcance” que contenga:

- **Entregables principales y secundarios:** resultados tangibles y verificables, desde prototipos hasta modelos productivos.
- **Exclusiones:** aspectos fuera del alcance para evitar expectativas irrealistas.
- **Recursos y restricciones:** equipos, datos, infraestructuras y limitaciones técnicas o normativas.
- **Criterios de aceptación:** parámetros que determinan cuándo un entregable puede considerarse válido.

4.2.3. *Roadmap y fases iterativas*

La definición del alcance se plasma en un **roadmap estructurado**, que combina claridad metodológica con flexibilidad adaptativa. Entre los hitos habituales se encuentran:

1. **Definición del caso de uso:** formulación inicial de objetivo y alcance.

2. **Diseño del prototipo o MVP (Minimum Viable Product):** construcción de una primera versión con funcionalidades esenciales.
3. **Piloto controlado:** validación en un entorno reducido y con métricas definidas.
4. **Escalado progresivo:** despliegue hacia contextos más amplios, garantizando replicabilidad y sostenibilidad.
5. **Consolidación y monitoreo:** institucionalización de la solución, con mecanismos de seguimiento ambiental y social.

Este esquema favorece la gestión de riesgos, evita desviaciones de alcance (*scope creep*) y permite aprender de iteraciones tempranas para mejorar la solución final.

4.2.4. Integración de la dimensión medioambiental

La sostenibilidad no debe abordarse como un añadido, sino como un **criterio estructural del objetivo y del alcance**. Esto implica:

- Incorporar métricas de desempeño ambiental en los criterios de éxito.
- Establecer límites de aplicación coherentes con políticas de economía circular o neutralidad climática.
- Evaluar desde el inicio la disponibilidad de datos ambientales de calidad para el entrenamiento de modelos.
- Asegurar que los objetivos del caso de uso están alineados con compromisos regulatorios (ej. European Green Deal, AI Act).

De esta manera, cada caso de uso no solo se orienta a la eficiencia tecnológica, sino también a la **creación de valor sostenible**, integrando impacto económico, social y ambiental.

4.3. Amenazas y vulnerabilidades

La identificación de amenazas y vulnerabilidades en sistemas de inteligencia artificial (IA) constituye un paso crítico en el proceso de definición de casos de uso. No se trata únicamente de evaluar riesgos técnicos, sino de comprender su impacto en la confianza, la sostenibilidad y la adopción responsable de estas tecnologías. Las principales áreas de riesgo se pueden estructurar en torno a los siguientes ejes:

4.3.1. Riesgos para la privacidad y la protección de datos

La IA opera sobre grandes volúmenes de datos, muchos de ellos sensibles. Amenazas como la **re-identificación de individuos en datasets anonimizados**, el uso indebido de información personal o la falta de cumplimiento de marcos regulatorios (como el RGPD en Europa) constituyen vulnerabilidades críticas. Además, la expansión de técnicas de machine learning

incrementa la superficie de exposición de datos, lo que obliga a incorporar desde el diseño (privacy by design) medidas como la privacidad diferencial, los datos sintéticos o el cifrado homomórfico.

4.3.2. Sesgos y equidad en los modelos

La dependencia de datos históricos introduce el riesgo de **reproducir y amplificar sesgos sociales, culturales o económicos**. Estos sesgos no solo afectan la equidad en la toma de decisiones, sino que deterioran la legitimidad del sistema de IA frente a la sociedad. La falta de representatividad de los datos o de mecanismos de validación adecuados puede generar resultados discriminatorios, especialmente en ámbitos como la contratación, la concesión de crédito o la gestión de recursos públicos.

4.3.3. Robustez, resiliencia y ataques adversariales

Los modelos de IA pueden ser objeto de ataques que manipulen sus entradas para alterar los resultados (*adversarial examples*), o que extraigan información sensible de los datos de entrenamiento (*data poisoning* y *model inversion*). Estas vulnerabilidades cuestionan la robustez del sistema y su capacidad para operar de manera confiable en entornos complejos o hostiles. La ausencia de mecanismos de defensa adecuados compromete no solo la seguridad técnica, sino también la continuidad de negocio y la confianza en el sistema.

4.3.4. Explicabilidad y trazabilidad

La falta de transparencia en algoritmos complejos, como los modelos de deep learning, genera una vulnerabilidad de tipo organizativo: la **incapacidad de explicar las decisiones de la IA** frente a auditores, reguladores o clientes. La opacidad del modelo dificulta la detección de errores, el análisis de sesgos y la implementación de medidas correctoras, creando un riesgo de cumplimiento normativo y reputacional.

4.3.5. Ciberseguridad aplicada a la IA

Los sistemas de IA, al integrarse en infraestructuras digitales críticas, se convierten en objetivos de ciberataques. Estos pueden dirigirse tanto a los datos como a los modelos o a las plataformas de despliegue. Entre los riesgos se encuentran la manipulación maliciosa de modelos, la denegación de servicio y la explotación de vulnerabilidades en entornos de aprendizaje federado. La protección de la IA requiere una aproximación en capas, que combine ciberseguridad tradicional con medidas específicas de protección de modelos.

4.3.6. Riesgos medioambientales y de sostenibilidad

Más allá de las amenazas técnicas, la IA plantea **vulnerabilidades relacionadas con el impacto medioambiental**. El entrenamiento de modelos de gran escala implica consumos energéticos y emisiones de carbono significativas. Esta dimensión, a menudo ignorada en la evaluación de riesgos, debe ser considerada como un elemento de vulnerabilidad organizativa y social, que

exige la adopción de métricas y políticas de eficiencia energética, así como la selección de soluciones que minimicen la huella ambiental.

4.3.7. Riesgos regulatorios y de cumplimiento

La evolución del marco normativo, tanto a nivel europeo (AI Act) como internacional, introduce un riesgo de incumplimiento para organizaciones que desarrollan o despliegan IA sin un marco de gobernanza adecuado. La falta de alineamiento con estos requisitos puede derivar en sanciones económicas, restricciones operativas y pérdida de legitimidad institucional.

4.4. Retos y problemas del caso de uso

El despliegue de un caso de uso de inteligencia artificial en el ámbito de la sostenibilidad exige reconocer, desde el inicio, los principales retos técnicos que condicionan su éxito. Estos desafíos no son meramente operativos, sino que afectan a la viabilidad a largo plazo de las soluciones y a su capacidad de generar impacto real.

4.4.1. Calidad y disponibilidad de los datos

La calidad de los datos constituye uno de los principales puntos críticos. Los modelos de IA dependen de la integridad, representatividad y consistencia de los datos de entrenamiento y operación. Conjuntos de datos incompletos, sesgados o heterogéneos degradan el rendimiento técnico y generan resultados poco fiables. Por ello, la gestión de datos debe considerarse un eje estratégico del caso de uso y no una tarea secundaria.

4.4.2. Integración con infraestructuras tecnológicas existentes

Los sistemas legados suelen presentar limitaciones de interoperabilidad y problemas de compatibilidad con arquitecturas modernas. La incorporación de modelos de IA en entornos productivos requiere inversiones en interfaces, pipelines de datos y plataformas de despliegue que aseguren escalabilidad, resiliencia y seguridad operativa.

4.4.3. Degradación y model drift

Con el tiempo, los modelos tienden a perder capacidad predictiva debido a la evolución de los datos o patrones de comportamiento. Detectar y mitigar estas desviaciones exige sistemas avanzados de monitorización y protocolos de recalibración periódica. La ausencia de estas medidas compromete la fiabilidad y el valor del caso de uso.

4.4.4. Robustez técnica y sostenibilidad del ciclo de vida

La implementación inicial puede arrojar resultados prometedores, pero sin un plan de mantenimiento los modelos corren el riesgo de quedar obsoletos. La trazabilidad y la explicabilidad de las decisiones automatizadas son requisitos crecientes, especialmente en sectores regulados y orientados a la sostenibilidad.

4.4.5. Complejidad en la gestión de proyectos de IA

Los proyectos de IA exigen metodologías consolidadas, perfiles profesionales especializados y recursos tecnológicos adecuados. La falta de estos elementos, sumada a los elevados costes de infraestructura y operación, se traduce en barreras que pueden reducir significativamente el retorno esperado del caso de uso.

4.5. Consideraciones de fiabilidad

La fiabilidad en los sistemas de inteligencia artificial (IA) no es un concepto aislado. Es la condición que asegura que la tecnología pueda ser adoptada, supervisada y utilizada con confianza tanto dentro de la organización como por parte de clientes, socios o reguladores. Un sistema fiable es aquel que:

1. Funciona de forma consistente en el tiempo.
2. Puede ser verificado y auditado.
3. Responde a las expectativas de todas las partes interesadas.
4. Genera confianza en el conjunto de la organización.

4.5.1. Consistencia técnica

El primer paso para garantizar fiabilidad es demostrar que la IA produce resultados **coherentes y reproducibles**. Para ello, las organizaciones deben aplicar un conjunto de prácticas técnicas que reduzcan la variabilidad:

- **Pruebas de estrés y escenarios adversos:** comprobar cómo responde el sistema ante cambios bruscos de datos o situaciones no previstas.
- **Monitorización en producción:** detectar desviaciones del modelo (model drift o data drift) que puedan alterar la calidad de los resultados.
- **Mantenimiento de modelos:** ajustar los algoritmos cuando cambian los patrones de los datos o el contexto operativo.
- **Redundancia y resiliencia:** contar con mecanismos alternativos que garanticen la continuidad si el sistema falla.

Un sistema consistente transmite seguridad: ofrece siempre resultados similares cuando se enfrenta a problemas similares.

4.5.2. Verificabilidad y auditabilidad

No basta con que el sistema “funcione”; hay que **poder demostrarlo**. La verificabilidad implica que el desempeño del sistema puede ser comprobado con métricas claras y, sobre todo, auditado de manera independiente.

- **Trazabilidad:** cada resultado del sistema debe estar vinculado a las fuentes de datos y a las decisiones intermedias que lo generaron.
- **Explicabilidad (XAI):** permitir que los usuarios y auditores entiendan por qué un algoritmo ha tomado una decisión concreta.
- **Auditorías periódicas:** tanto internas como externas, siguiendo marcos reconocidos (ej. NIST AI RMF en EE. UU. o las recomendaciones de la UE).
- **Registros documentales:** reportes de entrenamiento, validación y uso que sirvan como “caja negra” para supervisar la evolución del sistema.

Esta dimensión es especialmente relevante frente a reguladores y autoridades, ya que la fiabilidad no puede ser solo una percepción, sino un hecho probado.

4.5.3. Expectativas de los stakeholders

La fiabilidad no tiene el mismo significado para todos. Cada grupo de interés espera algo diferente del sistema:

- **Equipos internos:** buscan que la IA reduzca errores y mejore la eficiencia operativa. Un modelo que falla en tareas básicas pierde rápidamente credibilidad dentro de la organización.
- **Clientes y usuarios finales:** esperan resultados justos, transparentes y libres de sesgos. En este sentido, la fiabilidad también se vincula a la percepción de equidad.
- **Reguladores y supervisores:** exigen cumplimiento legal, seguridad, protección de datos y respeto a principios éticos. La fiabilidad, para ellos, es sinónimo de cumplimiento verificable.

Un buen sistema de gestión traduce estas expectativas en **indicadores medibles**, como tasas de error aceptables, acuerdos de nivel de servicio (SLAs), o métricas específicas de privacidad y seguridad.

4.5.4. Confianza organizacional y gobernanza

Asegurar la fiabilidad también implica dotarse de estructuras de gobernanza que velen por ella de forma continua. Las organizaciones más avanzadas han creado:

- Comités de IA responsables de supervisión y priorización.
- Foros de validación de modelos y gestión de riesgos.
- Órganos de auditoría internos y externos especializados en IA.

Estos espacios no solo revisan los aspectos técnicos, sino que alinean la fiabilidad con la estrategia de negocio y con los compromisos sociales y medioambientales de la organización. La gobernanza convierte la fiabilidad en un atributo **institucionalizado**, y no en un rasgo puntual de un proyecto concreto.

4.5.5. *Fiabilidad como ventaja competitiva*

Más allá de la obligación técnica o regulatoria, la fiabilidad se convierte en un **diferenciador estratégico**. Una IA percibida como fiable genera confianza en clientes, atrae colaboraciones con otras organizaciones y reduce riesgos reputacionales. De hecho, en un contexto donde la IA es cada vez más cuestionada por sesgos, falta de transparencia o impactos sociales, la fiabilidad puede marcar la diferencia entre una innovación aceptada o rechazada.

4.6. KPIs para medir el éxito

La medición del éxito en los casos de uso de inteligencia artificial exige un enfoque estructurado que combine objetividad, alineación estratégica y equilibrio entre métricas cuantitativas y cualitativas. Para evitar arbitrariedad en el proceso, resulta imprescindible definir un marco metodológico claro que guíe tanto la **creación** como la **validación** de los indicadores clave de desempeño (KPIs).

4.6.1. *Proceso de creación de KPIs*

El punto de partida es la definición compartida de qué significa “éxito” para cada parte interesada. Esto implica articular expectativas desde tres niveles:

- **Negocio**, donde los KPIs deben reflejar creación de valor, eficiencia y diferenciación en el mercado.
- **Tecnología**, donde se evalúa la robustez, escalabilidad y resiliencia del sistema de IA.
- **Sociedad y regulador**, donde la atención se centra en la sostenibilidad, el cumplimiento normativo y la confianza generada.

Una vez definido este marco, se recomienda establecer mecanismos de gobernanza que incluyan la participación de perfiles técnicos, de gestión y de validación ética, de manera que los KPIs no se reduzcan a métricas operativas desconectadas del impacto global.

4.6.2. *Categorías de KPIs*

Para que la medición sea integral, los KPIs se agrupan en cuatro grandes categorías:

- **KPIs técnicos**: reflejan la capacidad del sistema para operar de manera fiable y eficiente. Ejemplos: precisión en predicciones, disponibilidad del sistema, tiempos de respuesta, escalabilidad en producción.

- **KPIs de negocio:** cuantifican el impacto económico y la adopción organizativa. Ejemplos: ahorro en costes operativos, incremento de ingresos derivados de IA, porcentaje de procesos automatizados, tasa de adopción por parte de empleados o clientes.
- **KPIs de sostenibilidad:** miden el aporte al cumplimiento de objetivos medioambientales y sociales. Ejemplos: reducción de huella de carbono en procesos automatizados, eficiencia energética de los modelos, número de proyectos alineados con los ODS.
- **KPIs de confianza y gobernanza:** garantizan que el sistema se perciba como seguro, ético y regulatoriamente conforme. Ejemplos: frecuencia de auditorías realizadas, número de incidentes de sesgo detectados y corregidos, nivel de explicabilidad alcanzado en modelos críticos.

4.6.3. Ejemplos representativos

A nivel ilustrativo, se pueden plantear ejemplos de cada categoría:

Categoría	Ejemplo de KPI	Descripción de indicador
Técnicos	Precisión del modelo (%)	Porcentaje de aciertos en predicciones frente a datos reales
	Tiempo medio de respuesta [ms]	Velocidad con la que el sistema devuelve resultados en producción
	Disponibilidad del sistema [%]	Porcentaje de tiempo en que el sistema está plenamente operativo
	Incidentes críticos reportados [#]	Número de fallos técnicos en producción con impacto relevante.
	Consumo energético por inferencia [kWh]	Eficiencia energética de los modelos en producción.
De negocio	ROI del caso de uso [%]	Relación entre beneficios obtenidos y costes asociados a la implantación.
	Incremento de ingresos atribuibles a IA [%]	Mejora en ventas u otros ingresos generados por IA.
	Reducción de costes operativos [%]	Porcentaje de ahorro frente al proceso previo.

	Tasa de adopción interna [%]	<i>Proporción de empleados que utilizan activamente la solución.</i>
	Tiempo de puesta en producción [meses]	<i>Velocidad con la que se despliega un MVP o caso completo.</i>
De sostenibilidad	Reducción de emisiones de CO ₂ [t/año]	<i>Disminución de gases de efecto invernadero atribuibles al uso de IA.</i>
	Casos alineados con los ODS [%]	<i>Nivel de contribución de los proyectos a los Objetivos de Desarrollo Sostenible.</i>
	Consumo energético por entrenamiento [kWh]	<i>Impacto ambiental del entrenamiento de modelos.</i>
	Reducción de recursos físicos [%]	<i>Eficiencia en el uso de materiales gracias a digitalización con IA.</i>
De confianza y gobernanza	Auditorías de IA completadas [#]	<i>Verificaciones internas o externas de seguridad, ética y cumplimiento.</i>
	Sesgos detectados y corregidos [#]	<i>Casos identificados de discriminación y medidas correctivas aplicadas.</i>
	Explicabilidad del modelo [escala 1–5]	<i>Grado en que los outputs pueden ser interpretados por humanos.</i>
	Índice de satisfacción de usuarios [NPS, etc.]	<i>Percepción de confianza y valor aportado por la solución de IA.</i>
	Grado de cumplimiento regulatorio [%]	<i>Grado de conformidad frente a estándares o normativas (ej. GDPR, AI Act).</i>

4.6.4. Evaluación y criterios de aceptación

Definir los KPIs es solo el primer paso: su utilidad depende de establecer criterios claros de aceptación. Esto supone:

- Fijar **umbrales de desempeño** (ej. “precisión mínima del 90%” o “reducción de al menos un 15% en costes”).
- Garantizar la **revisión periódica** para ajustar los KPIs a medida que evolucionan el caso de uso, el mercado o las exigencias regulatorias.
- Incorporar **criterios cualitativos** como la percepción de confianza de clientes o la reputación organizativa, que aportan una dimensión que los datos duros no capturan.

4.6.5. *Equilibrio entre cuantitativo y cualitativo*

Un riesgo habitual en los proyectos de IA es sobreponderar los indicadores cuantitativos (precisión, ROI, ahorros), dejando en un segundo plano los cualitativos (confianza, satisfacción, reputación). El equilibrio entre ambos permite capturar no solo la eficiencia operativa, sino también la aceptación social y organizativa, elementos críticos para la sostenibilidad del caso de uso a largo plazo.

5. Selección de tecnologías aplicables

La selección de tecnologías constituye un factor crítico para garantizar la viabilidad y el impacto de un caso de uso de inteligencia artificial. No basta con conocer las opciones existentes; es necesario evaluar su madurez, eficiencia, sostenibilidad y compatibilidad con la estrategia de la organización. Este apartado organiza las principales tecnologías aplicables en seis bloques: modelos fundacionales, técnicas de reutilización, arquitecturas especializadas, despliegue sostenible, optimización mediante IA y casos de referencia.

5.1. Modelos preentrenados y fundacionales

Los modelos preentrenados y fundacionales constituyen la base tecnológica más extendida en la actualidad. Estos modelos, entrenados con grandes volúmenes de datos en múltiples dominios, ofrecen capacidades generalistas que pueden ser adaptadas a un amplio abanico de tareas específicas.

Su principal valor reside en la **reducción de costes y tiempos de desarrollo**, ya que permiten a las organizaciones aprovechar arquitecturas previamente entrenadas en lugar de desarrollar soluciones desde cero. Además, abren la puerta a funcionalidades avanzadas, como el procesamiento multimodal (texto, imagen, audio), el análisis de lenguaje natural a escala o la generación de contenido.

Entre los modelos más destacados se encuentran:

- **GPT y variantes abiertas (GPT-Neo, GPT-J)**, como ejemplos de modelos de lenguaje fundacionales.
- **CLIP**, orientado al vínculo entre texto e imagen.
- **Whisper**, especializado en reconocimiento de voz multilingüe.
- **EfficientNet**, modelo optimizado de visión con un enfoque eficiente en recursos.
- **DistilBERT y TinyML**, que representan líneas de trabajo orientadas a modelos más ligeros y sostenibles.

La evolución hacia modelos fundacionales más sostenibles ha llevado a desarrollar arquitecturas con menor huella energética, manteniendo un equilibrio entre rendimiento y eficiencia.

5.2. Métodos de reutilización y adaptación de modelos

Una de las estrategias más efectivas para aplicar IA de forma eficiente es la **reutilización de modelos existentes** mediante distintas técnicas de adaptación:

- **Transfer Learning (aprendizaje por transferencia):** permite reutilizar representaciones aprendidas en un dominio para aplicarlas a otro, con un coste computacional mucho menor que entrenar desde cero.
- **Knowledge Distillation (destilación de conocimiento):** técnica que comprime un modelo complejo en uno más pequeño, con un consumo energético reducido y tiempos de inferencia más rápidos.
- **Parameter-Efficient Fine-Tuning (PEFT):** métodos como *adapters* o *LoRA* permiten ajustar solo una parte del modelo, disminuyendo significativamente los recursos necesarios para su entrenamiento.
- **Modelos modulares:** arquitecturas que facilitan la combinación de componentes reutilizables, incrementando la flexibilidad.
- **Graph Neural Networks (GNNs):** aplicables a problemas con estructuras relacionales, como fraude financiero o redes logísticas, con un enfoque especialmente valioso en entornos complejos.

Estas técnicas son fundamentales para reducir los costes de entrenamiento, acelerar los ciclos de despliegue y minimizar el impacto ambiental asociado al cómputo intensivo.

5.3. Estrategias de despliegue sostenible

Una vez desarrollado o adaptado un modelo, su operación requiere de estrategias que aseguren un uso eficiente y responsable de los recursos:

- **Inferencia optimizada:** técnicas como la cuantización, la poda de parámetros o el uso de hardware especializado permiten reducir la latencia y el consumo energético durante la ejecución.
- **Escalabilidad sostenible:** aplicar políticas de inferencia a gran escala que equilibren calidad de resultados y consumo energético.
- **Aprovisionamiento dinámico de recursos:** asignar cómputo de manera flexible según la demanda, evitando infrautilización de infraestructura.

- **Despliegue en la nube con criterios de sostenibilidad:** aprovechar entornos de *green cloud* y proveedores con políticas de reducción de emisiones y uso de energías renovables.
- **Monitorización del impacto energético:** establecer métricas y KPIs (p. ej. *Power Usage Effectiveness*, intensidad de carbono del software) que permitan evaluar la huella operativa del sistema y asegurar su mejora continua.

5.4. IA para optimizar IA

La propia inteligencia artificial se utiliza como herramienta para mejorar la eficiencia de sus procesos internos:

- **Automated Machine Learning (AutoML):** selección automatizada de arquitecturas y parámetros para reducir tiempos de entrenamiento.
- **Neural Architecture Search (NAS):** exploración automatizada de arquitecturas que optimizan precisión y consumo energético.
- **Compiladores y optimización hardware-aware (ej. TVM):** traducción de modelos para ejecutar de forma óptima en hardware específico.

Esta categoría refleja la madurez del ecosistema tecnológico, donde la IA se convierte en un mecanismo de autooptimización, incrementando la escalabilidad y reduciendo la huella ambiental.

6. Análisis de impacto

El concepto de *impacto* en inteligencia artificial es heterogéneo y multifacético. No existe una única definición universal, ya que el significado depende del prisma desde el cual se evalúe: medioambiental, social, económico o regulatorio. De este modo, lo que para un área de la organización representa un beneficio tangible, para otra puede implicar un riesgo latente o un desafío ético. Esta diversidad obliga a adoptar un enfoque estructurado que permita comprender de forma integrada las consecuencias de cada caso de uso.

La principal dificultad reside en que los impactos rara vez son reducibles a un único indicador. Los efectos ambientales, como las emisiones de carbono o el consumo energético de la infraestructura tecnológica, resultan relativamente cuantificables. Sin embargo, los impactos sociales —como la confianza, la inclusión o la percepción ciudadana— presentan un carácter más intangible. Incluso en lo económico, las métricas tradicionales de coste-beneficio tienden a quedarse cortas si no se integran consideraciones de riesgo, sostenibilidad y legitimidad a largo plazo.

En los últimos años se han desarrollado marcos y estándares para guiar esta tarea. En el ámbito ambiental, los protocolos de medición de emisiones y las normas de gestión del ciclo de vida ofrecen un referente consolidado. Para el análisis social y de gobernanza, los marcos internacionales de reporte y las normativas europeas de sostenibilidad establecen directrices claras para incorporar factores intangibles. En lo económico, emergen metodologías complementarias a los enfoques financieros tradicionales, que integran el retorno social y ambiental junto al estrictamente monetario.

El análisis de impacto no debe concebirse como un ejercicio accesorio, sino como un pilar fundamental para asegurar la legitimidad y sostenibilidad de la inteligencia artificial en las organizaciones. Solo mediante un marco de evaluación consistente, transparente y alineado con los objetivos estratégicos es posible valorar de manera equilibrada los beneficios, riesgos y compromisos que implica cada caso de uso. Además, este análisis debe ser revisable y comparable en el tiempo, permitiendo generar aprendizajes acumulativos y fortalecer la posición frente a reguladores, clientes y sociedad en general.

6.1. Impacto medioambiental

El análisis del impacto medioambiental de la inteligencia artificial (IA) requiere una visión amplia, ya que sus efectos se manifiestan en distintos niveles y con intensidades variables. Estos impactos no son homogéneos: dependen de factores como la escala del modelo, la infraestructura utilizada, la localización geográfica o la procedencia de la energía. La literatura especializada distingue habitualmente entre impactos **directos**, derivados del consumo y la operación, e impactos **indirectos**, vinculados al ciclo de vida de los equipos y a la cadena de suministro.

6.1.1. Impactos directos

- **Consumo energético:** El entrenamiento de modelos avanzados de IA implica un gasto eléctrico considerable. La magnitud del impacto depende en gran medida de si la electricidad procede de fuentes renovables o de combustibles fósiles.
- **Uso de agua:** Los centros de datos que soportan el funcionamiento de la IA necesitan sistemas de refrigeración que emplean grandes volúmenes de agua. En regiones con estrés hídrico, esta dependencia puede convertirse en un factor crítico.
- **Emisiones derivadas del uso:** Aunque el entrenamiento concentra la mayor parte del consumo energético, la fase de inferencia también genera emisiones relevantes cuando los sistemas se aplican de forma intensiva y a gran escala.

6.1.2. Impactos indirectos

- **Residuos electrónicos (e-waste):** La renovación constante de hardware especializado (GPUs, TPUs y otros componentes) produce un flujo creciente de residuos electrónicos cuya gestión adecuada no siempre está garantizada.
- **Infraestructura tecnológica:** La construcción y ampliación de centros de datos, así como las inversiones necesarias en redes eléctricas y de telecomunicaciones, tienen una huella ambiental propia.
- **Extracción de minerales críticos:** La producción de dispositivos y componentes requiere litio, cobalto, níquel o tierras raras. La extracción de estos recursos implica deforestación, uso intensivo de agua y generación de emisiones, además de estar asociada a tensiones sociales y geopolíticas.

6.1.3. Metodologías de medición

El impacto ambiental puede medirse utilizando distintas metodologías comparativas que permiten evaluar casos de uso de forma estandarizada:

- **Análisis de Ciclo de Vida (LCA):** Considera todas las fases del sistema, desde la extracción de materias primas hasta el final de su vida útil.
- **Contabilidad de huella de carbono:** Calcula las emisiones de CO₂ equivalente, diferenciando entre emisiones directas, indirectas por consumo de energía y emisiones a lo largo de la cadena de valor.
- **Indicadores operativos:** Herramientas como el *Power Usage Effectiveness* (PUE) permiten medir la eficiencia energética de un centro de datos, mientras que los indicadores de consumo de agua aportan visibilidad sobre la huella hídrica.

6.1.4. Consideraciones de gestión

La incorporación de estas variables en el proceso de definición de casos de uso de IA resulta clave para tomar decisiones informadas. Algunas prácticas habituales incluyen:

- Comparar el impacto de distintas alternativas tecnológicas para seleccionar la opción más eficiente.
- Introducir criterios ambientales en los procesos de priorización y selección de casos de uso.
- Asegurar que la comunicación de estos impactos se integra en los reportes de sostenibilidad y en los compromisos ESG de la organización.

6.2. Impacto social

6.2.1. La necesidad de medir el impacto social

El impacto social de una iniciativa de inteligencia artificial aplicada a la sostenibilidad no puede quedar en el terreno de lo intangible o meramente declarativo. Para las partes interesadas — tanto internas como externas— resulta fundamental disponer de mecanismos que traduzcan la aportación de la IA a métricas observables y verificables. La medición no solo permite validar la efectividad de las intervenciones, sino que además facilita la toma de decisiones estratégicas, la rendición de cuentas y la comparación entre proyectos.

Al mismo tiempo, conviene subrayar la complejidad inherente al proceso: muchos de los resultados sociales tienen un carácter cualitativo, se materializan en horizontes temporales distintos y afectan a colectivos diversos. De ahí que sea imprescindible apoyarse en metodologías reconocidas que permitan dotar de rigor y comparabilidad a la evaluación.

6.2.2. Principales metodologías reconocidas

Existen diferentes marcos y metodologías de evaluación del impacto social que han alcanzado una amplia aceptación internacional. Entre ellos destacan:

- **SROI (Social Return on Investment):** Considerado como uno de los estándares más completos, el SROI traduce los resultados sociales, ambientales y económicos en términos monetarios, estableciendo un ratio entre la inversión realizada y el valor social generado. Su valor reside en que permite expresar, en una métrica sencilla, la rentabilidad social de un proyecto, algo fácilmente comprensible para gestores, inversores y reguladores.
- **Social Reporting Standard (SRS):** Marco de reporte que estandariza la manera de describir el impacto social de iniciativas y organizaciones. Su principal aportación es la transparencia y comparabilidad, ofreciendo una estructura clara para documentar objetivos, actividades, resultados e impactos, más allá de métricas exclusivamente financieras.
- **Teoría del Cambio:** Este enfoque parte de la identificación de los objetivos sociales deseados y define la cadena lógica de actividades, resultados intermedios e impactos finales que deben darse para alcanzarlos. Aunque no siempre incluye monetización, es un instrumento potente para alinear expectativas y verificar coherencia estratégica.
- **Modelo Lógico:** Similar a la Teoría del Cambio, pero más centrado en la relación entre inputs, outputs y outcomes. Su ventaja radica en la claridad y simplicidad para mapear cómo los recursos invertidos se convierten en resultados sociales.

- **Metodologías híbridas:** En la práctica, muchas organizaciones combinan métricas cuantitativas (ej. número de beneficiarios, reducción de emisiones) con cualitativas (ej. percepción de mejora en calidad de vida), logrando un enfoque más integral y representativo de la realidad.

Estos métodos, aunque distintos, coinciden en la necesidad de:

1. **Definir indicadores claros y verificables.**
2. **Vincular los resultados a objetivos estratégicos.**
3. **Incorporar tanto la perspectiva de los beneficiarios directos como la de la sociedad en su conjunto.**

La incorporación de estas metodologías al análisis del impacto social de la IA garantiza una mayor legitimidad, ayuda a evitar arbitrariedades y facilita que las organizaciones tomen decisiones basadas en evidencia, alineando sus estrategias tecnológicas con un compromiso real hacia la sostenibilidad y la equidad.

6.2.3. *Categorías de indicadores en impacto social*

A la hora de implementar estas metodologías, los indicadores suelen organizarse en categorías que permiten capturar distintas dimensiones del valor social:

1. **Indicadores cuantitativos:**

- Número de personas beneficiarias.
- Incremento en la empleabilidad de colectivos vulnerables.
- Porcentaje de reducción en la brecha digital.

2. **Indicadores cualitativos:**

- Percepción de mejora en bienestar subjetivo.
- Testimonios de comunidades beneficiadas.
- Calidad de las relaciones entre organización y stakeholders.

3. **Indicadores monetizados:**

- Cálculo del SROI (por ejemplo, 1€ invertido = 2,5€ de valor social generado).
- Valor estimado del ahorro en costes sociales (sanitarios, educativos, laborales) atribuibles al proyecto.

6.2.4. *Procesos de validación y transparencia*

No basta con definir indicadores; es necesario establecer criterios de aceptación que garanticen su fiabilidad y eviten arbitrariedad en la selección. Para ello, se recomienda:

- **Participación de stakeholders:** incluir a beneficiarios, reguladores y expertos en el diseño de métricas para asegurar relevancia y legitimidad.
- **Triangulación de datos:** combinar fuentes internas, encuestas externas y datos públicos.
- **Auditorías o validaciones independientes:** cada vez más empleadas para reforzar la credibilidad de los informes de impacto social.

La transparencia se convierte en un valor crítico: comunicar no solo los resultados positivos, sino también las limitaciones metodológicas y los aprendizajes obtenidos en el proceso.

6.2.5. *Retos en la medición del impacto social*

La aplicación de estas metodologías enfrenta varios desafíos:

- **Atribución:** determinar con precisión qué parte de un cambio social puede atribuirse al proyecto de IA y cuál a otros factores externos.
- **Temporalidad:** algunos impactos requieren años para manifestarse, lo que dificulta su integración en los ciclos de evaluación cortos.
- **Valoración monetaria:** traducir cambios cualitativos en cifras monetarias implica juicios de valor y asunciones que pueden ser discutibles.

Aun con estas limitaciones, la tendencia global apunta a la consolidación de métricas estandarizadas y auditables, lo que refuerza la credibilidad de las organizaciones que aplican IA con fines sostenibles.

6.3. **Impacto económico**

El impacto económico de la inteligencia artificial (IA) en el marco de los casos de uso no debe evaluarse únicamente en términos de ahorro de costes, sino también en su capacidad para transformar modelos de negocio, generar nuevas fuentes de ingresos y reforzar la competitividad de las organizaciones. En este sentido, la IA actúa como una **palanca doble**: por un lado, incrementa la eficiencia operativa al reducir tiempos y costes; por otro, impulsa la creación de valor a través de innovaciones en productos, servicios y procesos de gestión. En concreto, el impacto económico puede cuantificarse mediante una combinación de indicadores financieros directos e indirectos, alineados con los objetivos del negocio:

1. Ahorro de costes operativos

Medición de reducciones en horas de trabajo, costes de procesamiento, errores o reprocesos, comparando la situación previa y posterior a la adopción del caso de uso.

2. Incremento de ingresos

Estimación de nuevas fuentes de ingresos o mejoras en las existentes, como aumento de ventas, mejora del cross-selling/upselling, reducción del churn o aceleración del time-to-market.

3. Productividad y eficiencia

Indicadores como output por empleado, tiempo de ciclo de procesos clave o capacidad de absorción de mayor volumen de demanda sin incremento proporcional de costes.

4. Costes de implementación y operación

Consideración del coste total de propiedad (TCO): desarrollo, licencias, infraestructura, mantenimiento, gobierno del modelo y gestión del cambio.

5. Retorno de la inversión (ROI) y plazo de recuperación

Cálculo del ROI esperado y del payback period, utilizando escenarios conservadores, base y optimistas para reflejar la incertidumbre asociada.

6.3.1. Eficiencia operativa y optimización de costes

La aplicación de algoritmos de IA permite automatizar tareas repetitivas y de bajo valor añadido, reduciendo de forma significativa la dependencia de recursos humanos para procesos manuales. Estos sistemas contribuyen a minimizar errores, mejorar la velocidad de ejecución y disminuir gastos operativos recurrentes.

La integración de soluciones de IA en áreas como la gestión documental, la predicción de la demanda o la optimización de inventarios puede cuantificarse comparando indicadores clave antes y después de su implantación. En gestión documental, el ahorro se mide habitualmente en términos de reducción de horas dedicadas a tareas manuales (clasificación, búsqueda, validación), disminución de errores y menor necesidad de reprocesos, traducidos en costes laborales evitados. En predicción de la demanda, la mejora de la precisión se refleja en una reducción de roturas de stock y sobreinventario, con impacto directo en costes de almacenamiento, capital inmovilizado y pérdidas por ventas no realizadas. En optimización de inventarios, el ahorro puede expresarse como una disminución del nivel medio de stock manteniendo el mismo nivel de servicio, o como una mejora del ratio coste–servicio.

6.3.2. *Nuevos modelos de ingresos y transformación del negocio*

La IA no solo aporta eficiencia, también abre la puerta a la creación de **nuevos modelos de ingresos**. Las organizaciones que adoptan tecnologías avanzadas pueden desarrollar productos más personalizados, servicios basados en datos y nuevas propuestas de valor para sus clientes.

6.3.3. *Resiliencia y competitividad empresarial*

El impacto económico de la IA también se refleja en la **resiliencia** frente a cambios del entorno. Las organizaciones que integran estas tecnologías en la toma de decisiones, en la detección temprana de riesgos o en la modelización de escenarios, refuerzan su capacidad de adaptación y aseguran su posición competitiva.

En sectores como el financiero, la IA se ha consolidado como un factor clave para la gestión del riesgo, la detección de fraude y la optimización de carteras. En términos más amplios, su aplicación en la dirección estratégica permite acelerar la capacidad de respuesta a nuevas oportunidades de mercado.

7. Evaluación de la viabilidad

La evaluación de un caso de uso de inteligencia artificial constituye una fase esencial en su ciclo de vida. A diferencia del análisis de impactos, que describe los efectos económicos, sociales y medioambientales, la evaluación tiene como finalidad **determinar la conveniencia, viabilidad y alineamiento estratégico** del caso con la organización. Se trata de un proceso que permite discriminar entre iniciativas, reducir riesgos y priorizar la asignación de recursos hacia aquellas con mayor potencial de valor.

La evaluación debe abordarse como un ejercicio **multidimensional**, en el que confluyen consideraciones regulatorias, estratégicas, tecnológicas, operativas y financieras. Esta visión integral asegura que las decisiones no se limiten a la rentabilidad inmediata, sino que incorporen factores de cumplimiento normativo, sostenibilidad, madurez organizativa y capacidad de ejecución.

Desde la perspectiva de gestión, resulta clave articular criterios objetivos que permitan vincular cada caso con los objetivos corporativos, comprobar su compatibilidad con los sistemas existentes, estimar sus costes y beneficios, y garantizar que pueda ser sostenido y escalado en el tiempo. La formalización de estos criterios evita la arbitrariedad y dota a las organizaciones de un marco claro para la toma de decisiones.

En este sentido, la evaluación de casos de uso debe entenderse no solo como un filtro previo al despliegue, sino también como un **mecanismo de gobernanza** que refuerza la transparencia y la confianza de los distintos grupos de interés. Una metodología sólida de evaluación

contribuye a que los proyectos de IA se implementen de manera responsable, alineada con la estrategia de la organización y capaz de generar beneficios sostenibles a lo largo del tiempo.

7.1. Aspectos legales y éticos

El cumplimiento normativo constituye el primer umbral en la evaluación de un caso de uso de inteligencia artificial. Su finalidad es asegurar que la iniciativa se ajusta tanto a las exigencias regulatorias como a las políticas internas de la organización, evitando riesgos legales, éticos o reputacionales que comprometan su legitimidad.

Este eje debe considerarse desde una **doble perspectiva**:

- **Externa**, orientada a la conformidad con marcos regulatorios de protección de datos, seguridad de la información, normas sectoriales y principios internacionales de confianza en IA.
- **Interna**, vinculada a la coherencia con códigos éticos, políticas de gobernanza del dato, directrices de sostenibilidad y estándares corporativos de riesgo.

El método de evaluación consiste en **inventariar una serie de ítems agrupados por categorías de riesgo** —legales, éticos, reputacionales, de seguridad o de gobernanza— y analizar su grado de cumplimiento. El resultado de esta valoración se traduce en un esquema **binario (OK/KO)**, complementado con la identificación de riesgos residuales y posibles medidas de mitigación. De esta forma, se garantiza simplicidad en la toma de decisiones sin renunciar a la profundidad necesaria para asegurar la trazabilidad del proceso.

El eje de compliance, por tanto, no solo verifica la viabilidad legal y ética de un caso de uso, sino que también refuerza la transparencia y la confianza de los distintos grupos de interés. Constituye un filtro inicial imprescindible: únicamente aquellas iniciativas que superen este umbral podrán avanzar hacia las siguientes fases de evaluación y priorización.

7.2. Alineación con la estrategia empresarial

La integración de un caso de uso de inteligencia artificial en una organización no debe evaluarse únicamente en función de su viabilidad técnica o de sus beneficios económicos inmediatos. Es fundamental determinar si la iniciativa está **alineada con los objetivos estratégicos** definidos por la entidad. Este eje garantiza que los esfuerzos en IA se traduzcan en resultados tangibles que refuercen la misión corporativa y que, al mismo tiempo, contribuyan a la sostenibilidad de la ventaja competitiva.

El proceso de evaluación debe comenzar por identificar los **drivers estratégicos de la organización**, tales como la mejora de la eficiencia operativa, el impulso de la innovación, la orientación al cliente, la sostenibilidad medioambiental o el fortalecimiento de la resiliencia

empresarial. Cada caso de uso debe ser analizado en relación con estos ejes para determinar de qué manera contribuye, directa o indirectamente, a su consecución.

La metodología de análisis consiste en establecer un **mapeo explícito entre el caso de uso y las líneas estratégicas corporativas**. Esta vinculación permite clasificar los casos en función de su nivel de alineamiento (alto, medio, bajo), generando una base objetiva para la toma de decisiones. Un caso con bajo nivel de alineamiento, aunque pueda mostrar un retorno económico en el corto plazo, puede carecer de legitimidad si no aporta a las metas que la organización ha fijado como prioritarias.

Asimismo, resulta relevante integrar esta evaluación con instrumentos de planificación como los **roadmaps estratégicos** y marcos de gestión empresarial. Esta integración asegura que el caso de uso no solo responda a necesidades puntuales, sino que se inserte en un proceso continuo de transformación y creación de valor.

El eje de estrategia empresarial actúa como un **filtro de relevancia**, orientando la selección de casos de uso hacia aquellos que no solo son viables o rentables, sino que también consolidan la dirección futura de la organización. Este enfoque permite que la inversión en inteligencia artificial se traduzca en una palanca real de transformación y en un factor de refuerzo de la visión corporativa a medio y largo plazo.

7.3. Criterios tecnológicos

La viabilidad tecnológica de un caso de uso de inteligencia artificial no depende únicamente de su funcionalidad o del rendimiento esperado, sino de su **capacidad de integrarse de manera coherente y sostenible en el ecosistema tecnológico de la organización**. Este eje de evaluación busca garantizar que la solución propuesta no se convierta en una iniciativa aislada, difícil de mantener o incompatible con la evolución estratégica de los sistemas corporativos.

Un primer aspecto a considerar es la **compatibilidad tecnológica**. El caso de uso debe ser capaz de interactuar de forma fluida con las plataformas y sistemas ya existentes —desde bases de datos y repositorios de información hasta soluciones de gestión empresarial y herramientas analíticas—. La integración ineficiente, las redundancias funcionales o la creación de sistemas paralelos sin conectividad generan sobrecostos y riesgos operativos que limitan el valor añadido de la iniciativa.

En segundo lugar, la evaluación debe contemplar el **alineamiento con el plan de sistemas**. La mayoría de organizaciones disponen de una estrategia tecnológica definida, que incluye objetivos de modernización de infraestructuras, migración a entornos cloud, adopción de plataformas de datos unificadas o estandarización de herramientas analíticas. Cualquier caso de

uso que no se inserte en este marco puede requerir inversiones adicionales no previstas, comprometer plazos o dificultar la evolución de la arquitectura tecnológica.

Otro elemento esencial es la **huella de carbono y la sostenibilidad de los sistemas de IA**. El entrenamiento y operación de modelos de gran escala tienen un impacto energético considerable, que debe evaluarse en términos de consumo, emisiones asociadas y alternativas disponibles. Optar por modelos preentrenados, aplicar técnicas de optimización de hardware o emplear infraestructuras energéticamente eficientes son medidas que contribuyen a reducir este impacto. Incluir este análisis en la evaluación tecnológica no solo responde a una exigencia ética y de compliance, sino que además fortalece la reputación de la organización en su compromiso con la sostenibilidad.

Finalmente, la **escalabilidad y resiliencia** completan la valoración tecnológica. Un caso de uso debe ser capaz de replicarse en distintas áreas o geografías, adaptarse a cambios en el volumen de datos o en la demanda de usuarios, y mantener su operatividad ante posibles fallos técnicos. La robustez del sistema, la facilidad de mantenimiento y la existencia de planes de contingencia son factores determinantes para asegurar su viabilidad en el medio y largo plazo.

En síntesis, el eje tecnológico evalúa no solo si el caso de uso es técnicamente viable, sino si lo es de forma **coherente, alineada y sostenible**. La integración con sistemas existentes, el ajuste al plan estratégico de tecnología, la gestión responsable de la huella ambiental y la capacidad de escalar con resiliencia son condiciones indispensables para que un caso de uso aporte valor real y duradero a la organización.

7.3.1. Metodología de evaluación simplificada

- **Checklist estructurada:** agrupar los ítems de valoración en tres bloques: compatibilidad y alineamiento, sostenibilidad, y escalabilidad/resiliencia.
- **Valoración binaria:** clasificar cada ítem como OK/KO, reservando análisis más detallados para casos complejos o críticos.
- **Decisión y riesgos residuales:** considerar el caso apto solo si obtiene un OK en compatibilidad y alineamiento. En sostenibilidad y escalabilidad se permite avanzar con un plan de mitigación documentado.

7.4. Criterios operativos

La dimensión operativa de un caso de uso de inteligencia artificial hace referencia a la **capacidad de la organización para ponerlo en marcha, mantenerlo y escalarlo de forma eficiente**. No se trata únicamente de que el sistema funcione en un entorno de pruebas, sino de garantizar que puede sostenerse en la práctica con procesos, equipos y recursos adecuados.

Los principales aspectos a evaluar son:

1. Disponibilidad y calidad de los datos en operación

- Verificar que los flujos de datos necesarios están disponibles con la frecuencia y calidad requerida.
- En casos basados en modelos de lenguaje o generativos, analizar la **volumetría de tokens** y el coste asociado a su procesamiento, dado que impacta directamente en la viabilidad operativa.

2. Procesos y capacidades organizativas

- Identificar si la organización dispone de roles, herramientas y procedimientos básicos para mantener el sistema en producción.
- Evaluar la capacidad de monitorizar el rendimiento, resolver incidencias y ajustar los modelos cuando sea necesario.

3. Escalabilidad y sostenibilidad operativa

- Determinar si el sistema puede escalar en función de la demanda sin que los costes operativos crezcan de manera desproporcionada.
- Analizar si el consumo de recursos (cómputo, almacenamiento, tokens procesados) es compatible con los presupuestos y políticas de eficiencia de la organización.

7.4.1. Metodología de evaluación simplificada

1. **Checklist operativa:** verificar que se cubren los aspectos mínimos de datos, procesos y escalabilidad.
2. **Valoración binaria (OK/KO):** el caso de uso solo avanza si los datos y procesos operativos están garantizados.
3. **Análisis de volumetría:** estimar, a alto nivel, el consumo de datos o tokens y su impacto en OPEX, con planes de mitigación si se prevé un crecimiento elevado.

7.5. Relación coste-beneficio

La evaluación de la relación coste-beneficio constituye un componente esencial en la priorización de casos de uso de inteligencia artificial. Este análisis permite determinar si la inversión necesaria para desarrollar y mantener una iniciativa se justifica frente al valor que aporta a la organización, ya sea en términos económicos, estratégicos o reputacionales.

El primer paso consiste en identificar y clasificar los **costes asociados al ciclo de vida del caso de uso**. En el plano de la inversión inicial, o **CAPEX**, se incluyen los gastos vinculados al diseño,

entrenamiento de modelos, adquisición de licencias, infraestructura tecnológica y recursos humanos necesarios para la fase de arranque. En paralelo, es fundamental evaluar los **costes operativos recurrentes, u OPEX**, que comprenden elementos como el procesamiento de datos y tokens, el consumo energético, la monitorización continua, el almacenamiento y la intervención de personal especializado para el mantenimiento del sistema.

En contrapartida, deben analizarse los **beneficios esperados**. Estos se dividen en dos categorías:

- **Beneficios tangibles**, como ahorros de costes operativos, incremento de ingresos, mejoras en la productividad o reducción de errores.
- **Beneficios intangibles**, entre los que se incluyen la mejora de la reputación institucional, el fortalecimiento del cumplimiento normativo, el refuerzo de la confianza de clientes y socios, y la contribución a objetivos de sostenibilidad.

El análisis debe incorporar también el **horizonte temporal** en el que se materializan los beneficios. No todos los casos de uso generan retornos inmediatos; algunos requieren un período de amortización más prolongado. En este sentido, resulta útil trabajar con escenarios diferenciados (conservador, intermedio y optimista) que permitan estimar de manera más realista la evolución de la relación coste-beneficio.

La metodología de valoración combina métricas financieras reconocidas, como el retorno de la inversión (ROI), el coste total de propiedad (TCO) y el período de amortización o *payback*. En paralelo, marcos más específicos de análisis, como el retorno sobre la inteligencia artificial (ROAI), ofrecen herramientas para cuantificar el valor derivado de casos de uso que generan beneficios tanto tangibles como intangibles. La incorporación de estos instrumentos dota al análisis de rigor y comparabilidad entre distintas iniciativas.

El resultado final de la evaluación se expresa en una clasificación del caso de uso en función de su balance coste-beneficio: **favorable, neutro o desfavorable**. Este resultado sirve como criterio de decisión sobre el avance o descarte de cada iniciativa, asegurando que los recursos se orienten hacia proyectos capaces de generar un impacto sostenible y alineado con los objetivos estratégicos de la organización

8. Priorización y selección

La identificación y evaluación de casos de uso de inteligencia artificial generan un conjunto amplio y heterogéneo de iniciativas potenciales. Sin embargo, no todas tienen la misma relevancia, factibilidad o aportación estratégica. De ahí la necesidad de contar con una

metodología sistemática de priorización y selección, que permita a la organización tomar decisiones objetivas, transparentes y alineadas con sus metas.

El propósito de este apartado es ofrecer un marco de trabajo que facilite la transición desde la **evaluación individual de cada caso de uso** (bloque 4) hacia la **construcción de un portafolio de iniciativas priorizadas**, que maximice el valor generado y optimice el uso de recursos.

5.1 Principios de la priorización

La metodología se apoya en una serie de principios básicos:

1. **Transparencia:** los criterios de evaluación y priorización deben ser claros, conocidos por todos los actores relevantes y aplicados de forma homogénea.
2. **Comparabilidad:** los casos deben analizarse con métricas comunes que permitan establecer un orden objetivo y replicable.
3. **Flexibilidad:** la metodología debe adaptarse a la estrategia particular de la organización, ajustando pesos o criterios según el sector, la madurez digital o el contexto regulatorio.
4. **Escalabilidad:** el marco debe servir tanto para evaluar un número reducido de casos como para gestionar un portafolio amplio y dinámico.
5. **Balance estratégico:** no se trata solo de escoger los casos más rentables en el corto plazo, sino de construir un portafolio equilibrado que combine eficiencia, innovación y sostenibilidad.

5.2 Estructura de la metodología

La metodología de priorización y selección se compone de cinco etapas secuenciales:

- **1. Definición de criterios y pesos**

Los cinco ejes definidos en el bloque anterior constituyen la base del modelo:

- **Compliance:** filtro umbral obligatorio.
- **Estrategia empresarial:** contribución a los objetivos estratégicos de la organización.
- **Criterios tecnológicos:** compatibilidad, alineamiento con el plan de sistemas y sostenibilidad.
- **Criterios operativos:** viabilidad de puesta en marcha, mantenimiento y escalabilidad.
- **Relación coste-beneficio:** análisis financiero y de valor generado.

Cada eje recibe un **peso relativo** en función de la importancia que la organización otorgue a cada dimensión. Por ejemplo, estrategia y coste-beneficio pueden recibir un peso superior, mientras que tecnología y operación actúan como criterios habilitadores.

2. Evaluación individual (scoring)

Cada caso de uso se puntúa en los distintos ejes siguiendo una escala simple y objetiva (ej. 0–2 o 0–5).

- **Compliance** se evalúa en formato binario (OK/KO). Cualquier KO implica la exclusión inmediata del caso.
- Los demás ejes se valoran con una puntuación graduada, acompañada de una justificación breve que documente la decisión.

- **3. Cálculo de la puntuación global**

La puntuación de cada eje se multiplica por su peso y se consolida en una **puntuación final ponderada**.

Este cálculo permite obtener una representación objetiva y numérica del valor relativo de cada caso, facilitando su comparación en conjunto.

4. Tierización y categorización

En función de la puntuación final, los casos se agrupan en tres categorías principales:

- **Tier 1 (Alta prioridad)**: casos estratégicos, con elevada viabilidad y beneficios claros. Son los que avanzan a despliegue inmediato.
- **Tier 2 (Media prioridad)**: casos con potencial, pero que requieren ajustes técnicos, organizativos o financieros antes de ser implementados.
- **Tier 3 (Baja prioridad)**: casos con baja aportación, riesgos significativos o retorno limitado. Se posponen o descartan.

La tierización simplifica la toma de decisiones y facilita la comunicación a los órganos de gobierno.

5. Revisión cualitativa y construcción del portafolio

Aunque el scoring proporciona una base cuantitativa, resulta indispensable realizar una **revisión cualitativa** con los principales stakeholders (dirección, áreas de negocio, tecnología, compliance). Esta fase permite incorporar matices no capturados en la puntuación, como la necesidad de innovar en determinados segmentos, la presión regulatoria o la oportunidad de reforzar la reputación institucional.

El resultado final es la **construcción de un portafolio de casos de uso**, que combine:

- **Quick wins:** casos de retorno rápido y bajo riesgo.
- **Iniciativas estratégicas:** proyectos de mayor alcance, alineados con la visión a largo plazo.
- **Casos experimentales:** exploraciones innovadoras que aportan aprendizaje y posicionamiento futuro

Bibliografía

[How Companies Can Mitigate AI's Growing Environmental Footprint .](#)

- [How AI Can Speed Climate Action](#)
- [From Potential to Profit: Closing the AI Impact Gap](#)
- [Generative AI – Energy Use and Environmental Impacts](#)
- [Integrating ESG and AI: A Comprehensive Responsible AI Assessment Framework](#)

[NIST \(2023\). Artificial Intelligence Risk Management Framework \(AI RMF 1.0\).](#)

- [Unión Europea \(2024\). Artificial Intelligence Act.](#)
- [Unión Europea \(2023\). Corporate Sustainability Reporting Directive \(CSRD\).](#)
- [DOUE – Directiva \(UE\) 2022/2464](#)

[Unión Europea \(2023\). Energy Efficiency Directive \(EED\).](#)

[The Weight of Light: AI, Computation, and the Cost of Thinking Big.](#)

- [AI and the Future of Business and Economic Growth.](#)
- [The Future of Work Is Digital and Green.](#)
- [¿Es sostenible la inteligencia artificial?](#)
- [Navigating the AI startup landscape](#)

[Unión Europea \(2024\). Reglamento de Inteligencia Artificial \(AI Act\).](#)

- [NIST \(2023\). AI Risk Management Framework \(AI RMF 1.0\).](#)
- [Principios sobre Inteligencia Artificial.](#)

· [Comisión Europea \(2023\). Corporate Sustainability Reporting Directive \(CSRD – Directiva 2022/2464\).](#)
DOUE

· [Comisión Europea \(2019\). Ethics Guidelines for Trustworthy AI.](#)

· [Reglamento General de Protección de Datos \(2016/679\). DOUE – GDPR](#)

[European Commission – Better Regulation Toolbox \(Cap. 7\)](#)

· [OECD – Oslo Manual 2018](#)

· [The European environment — state and outlook 2020](#)

· [Artificial Intelligence Act \(AI Act\)](#)

· [Design Thinking Bootleg](#)

· [From partnerships to experience ecosystems](#)

· [Escalar la sostenibilidad a través de la innovación](#)

· [Artificial Intelligence for Efficiency, Sustainability and Inclusivity in TradeTech](#)

· [BCG – Accelerating Climate Action with AI](#)

· [Columbia Climate School – Landscape Assessment of AI for Climate & Nature](#)

· [A Guide to the Project Management Body of Knowledge \(PMBOK® Guide\).](#)

· [CEPAL. Metodología del Marco Lógico para la planificación, el seguimiento y la evaluación de proyectos.](#)

· [European Commission. Artificial Intelligence Act.](#)

· [OECD. Artificial Intelligence in Society. OECD Publishing, 2019.](#)

· [World Economic Forum. Empowering AI Leadership: An Oversight Toolkit for Boards of Directors, 2020.](#)

· [A Guide to the Project Management Body of Knowledge \(PMBOK® Guide\).](#)

· [CEPAL. Metodología del Marco Lógico para la planificación, el seguimiento y la evaluación de proyectos.](#)

· [European Commission. Artificial Intelligence Act.](#)

· [OECD. Artificial Intelligence in Society. OECD Publishing, 2019.](#)

· [World Economic Forum. Empowering AI Leadership: An Oversight Toolkit for Boards of Directors, 2020.](#)

[OECD \(2024\). AI, Data Governance and Privacy: Synergies and Areas of International Co-operation.](#)

· [OECD \(2023\). Advancing Accountability in AI.](#)

- [NIST \(2023\). *AI Risk Management Framework 1.0*.](#)
- [JRC – *Robustness and Explainability of Artificial Intelligence*.](#)
- [OECD \(2025\). *Sharing Trustworthy AI Models with Privacy-Enhancing Technologies*.](#)
- [ENISA \(2021\). *Multilayer Framework for Good Cybersecurity Practices for AI*.](#)
- [WEF \(2025\). *Artificial Intelligence and Cybersecurity: Balancing Risks and Rewards*.](#)
- [Stanford HAI \(2025\). *AI Index Report 2025 – Chapter 3: AI Incidents and Risks*.](#)
- [Rodríguez-Barroso, N. et al. \(2022\). *Survey on Federated Learning Threats*](#)
- [RAND Corporation \(2021\). *The Root Causes of Failure for Artificial Intelligence Projects*.](#)
- [FRA \(2019\). *Data quality and artificial intelligence*. European Union Agency for Fundamental Rights.](#)
- [Carnegie Mellon University – SEI \(2022\). *Realistic drift detection in production ML*.](#)
- [Nature \(2022\). *Temporal quality degradation in AI models*.](#)
- [MDPI \(2023\). *Challenges of Integrating AI in Software Project Management*.](#)
- [Kinney, D. et al. \(2024\). *Expectation management in AI: A framework for end-user expectations*.](#)
- [NIST \(2023\). *AI Risk Management Framework*. National Institute of Standards and Technology.](#)
- [Nature \(2024\). *Trust in AI: progress, challenges, and future directions*.](#)
- [IIA / PDPC \(2024\). *AI Auditing Frameworks*. AuditBoard](#)
- [Ciampaglia, G. et al. \(2025\). *Artificial intelligence auditability and auditor readiness*. ScienceDirect](#)
- [Manheim, D. et al. \(2024\). *AI Audit Standards Board: A Proposal for Trustworthy AI Governance*. arXiv](#)
- [McKinsey & Company – *Global AI Survey: AI proves its worth, but few scale impact*](#)
- [BCG – *How AI-Powered KPIs Measure Success Better*](#)
- [MIT Sloan Management Review – *The Future of Strategic Measurement: Enhancing KPIs with AI*](#)
- [ArXiv – *The Problem with Metrics Is a Fundamental Problem for AI* \(Thomas & Uminsky, 2020\)](#)

- NIST – Artificial Intelligence Risk Management Framework (AI RMF 1.0)
- ISO/IEC 42001:2023 – Artificial Intelligence Management System (AIMS).
- European Commission – Assessment List for Trustworthy AI (ALTAI) (2020).
- appliedAI (UnternehmerTUM) – *Value Assessment of AI Products and Applications*
- Boston Consulting Group (BCG) – *Where's the Value in AI?* (2024).
- MIT Sloan Management Review – *How to Find the Right Business Use Cases for Generative AI* (2023).
- McKinsey & Company – *The State of AI in 2023: Generative AI's Breakout Year.*