



Facultad de Ciencias Económicas y Empresariales
ICADE

**EL IMPACTO DE LA INTELIGENCIA
ARTIFICIAL Y EL BIG DATA EN LA
SOSTENIBILIDAD INDUSTRIAL:
APLICACIONES Y DESAFÍOS EN
SECTORES CLAVE**

Autor: Valeria Cagigas Gabriel
Director: Raúl González Fabre

MADRID | Marzo 2025

Resumen Ejecutivo

La creciente presión por alcanzar los Objetivos de Desarrollo Sostenible (ODS) y la importancia de luchar contra el cambio climático, han posicionado a los sectores industriales clave, como el carbono, el acero, el cemento, el petróleo, el papel, el aluminio y el químico, en el centro del debate sobre sostenibilidad. A pesar de su elevado impacto ambiental, estos sectores pueden ser capaces de contribuir a la transición ambiental a través del uso de tecnologías de vanguardia.

Este Trabajo de Fin de Grado analiza el papel de la Inteligencia Artificial (IA) y el Big Data (BD) en la mejora de la sostenibilidad en estos sectores industriales intensivos. En un contexto donde la presión de las regulaciones y la presión gubernamental son cada vez mayores, estas tecnologías surgen como herramientas clave para reducir emisiones, optimizar procesos y avanzar hacia los objetivos Net Zero.

El estudio identifica las principales barreras sectoriales —económicas, tecnológicas y organizativas— que dificultan la adopción de Inteligencia Artificial y Big Data, y analiza cómo su implementación es diferente según las características de cada industria. Asimismo, se presentan los desafíos y barreras derivados de la propia digitalización, como los altos costes iniciales, la falta de personal cualificado o el impacto ambiental de los sistemas digitales.

Este trabajo ofrece una visión crítica y estructurada sobre cómo estas tecnologías pueden contribuir a una transición industrial más sostenible, si se aplican con estrategias adaptadas, inversión adecuada y visión a largo plazo.

Palabras clave: sostenibilidad industrial, reducción de emisiones, Inteligencia Artificial, Big Data, digitalización, Net Zero, sectores industriales, barreras sectoriales.

Executive Summary

The growing pressure to achieve the Sustainable Development Goals (SDGs) and the importance of assessing climate change have placed key industrial sectors—such as carbon, steel, cement, oil, paper, aluminum, and chemicals—at the center of the sustainability debate. Despite their high environmental impact, these sectors have the potential to contribute to the environmental transition using cutting-edge technologies.

This paper analyzes the role of Artificial Intelligence (AI) and Big Data (BD) in improving sustainability within these carbon-intensive industrial sectors. In a context where regulatory and governmental pressure is increasing, these technologies emerge as key tools for reducing emissions, optimizing processes, and advancing toward Net Zero targets.

The study identifies the main sectoral barriers—economic, technological, and organizational—that are involved in the adoption of Artificial Intelligence and Big Data and examines how their implementation varies depending on the characteristics of each industry. Furthermore, it addresses the challenges and barriers derived from digitalization itself, such as high initial costs, the lack of qualified personnel, or the environmental impact of digital systems.

This work offers a critical and structured perspective on how these technologies can contribute to a more sustainable industrial transition if applied with adapted strategies, proper investment, and a long-term vision.

Keywords: industrial sustainability, emission reduction, Artificial Intelligence, Big Data, digitalization, Net Zero, industrial sectors, sectoral barriers.

ÍNDICE

| | |
|---|----|
| 1. INTRODUCCIÓN | 9 |
| 1.1. Justificación y relevancia del tema elegido | 9 |
| 1.2. Objetivo principal y objetivos secundarios..... | 10 |
| 1.3. Metodología empleada..... | 11 |
| 2. MARCO TEÓRICO | 12 |
| 2.1. Que es la sostenibilidad y cómo se aplica en los sectores industriales..... | 12 |
| 2.2. Big Data aplicado a la gestión de emisiones..... | 13 |
| 2.3. IA aplicada a la reducción de emisiones..... | 15 |
| 2.4. Objetivos de Desarrollo Sostenible (ODS) relacionados..... | 16 |
| 3. DESARROLLO | 17 |
| 3.1. Exploración datos de sostenibilidad | 17 |
| 3.1.1. Criterios de selección de sectores y empresas analizadas..... | 17 |
| 3.1.2. Introducción al análisis y muestra empleada | 17 |
| 3.1.3. Análisis Objetivos Net Zero..... | 20 |
| 3.1.4. Cobertura de gases en los diferentes sectores | 21 |
| 3.1.5. Planes de Transición. Compromiso de estrategias para alcanzar objetivos (Scope 1, Scope 2 y Scope 3)..... | 24 |
| 3.1.6. Obtención datos Big Data por sector | 26 |
| 3.2. Diferencias y barreras en la sostenibilidad sectorial | 28 |
| 3.2.1. Análisis de las diferencias y barreras en el sector del Aluminio..... | 29 |
| 3.2.2. Análisis de las diferencias y barreras en el sector Químico..... | 30 |
| 3.2.3. Análisis de las diferencias y barreras en el sector del Cemento..... | 31 |
| 3.2.4. Análisis de las diferencias y barreras en el sector del Petróleo..... | 32 |
| 3.2.5. Análisis de las diferencias y barreras en el sector del Papel. | 33 |
| 3.2.6. Análisis de las diferencias y barreras en el sector del Acero. | 34 |
| 4. IMPACTO DE LA INTELIGENCIA ARTIFICIAL Y EL BIG DATA EN LA SOSTENIBILIDAD INDUSTRIAL | 35 |
| 4.1. El papel de la IA y BD en la superación de barreras sectoriales..... | 35 |
| 4.2. BD e IA para el monitoreo de emisiones..... | 38 |
| 4.3. Desafíos en la implementación de técnicas de BD e IA..... | 42 |
| 5. CONCLUSIÓN | 44 |
| 6. DECLARACIÓN DE USO DE INTELIGENCIA ARTIFICIAL | 45 |

| | |
|--|----|
| 7. BIBLIOGRAFÍA | 47 |
| 8. ANEXOS | 55 |
| 8.1. Anexo I. Código empleado para la realización de las Ilustraciones y análisis de bases de datos..... | 55 |

ÍNDICE DE ILUSTRACIONES

| | |
|--|----|
| Ilustración 1. Número de Empresas Analizadas por Sector..... | 19 |
| Ilustración 2. Años Objetivo Net Zero | 20 |
| Ilustración 4. Gases Industria Química..... | 23 |
| Ilustración 3. Gases Industria Aluminio | 23 |
| Ilustración 5. Gases Industria Petróleo. | 23 |
| Ilustración 6. Gases Industria Cemento. | 23 |
| Ilustración 7. Gases Industria Acero. | 23 |
| Ilustración 8. Gases Industria Papel. | 23 |
| Ilustración 9. Cobertura de Compromisos en Alcances (Scope 1, 2 y 3)..... | 25 |
| Ilustración 10. Adopción de Big Data por sectores y categorías. | 27 |
| Ilustración 11. Porcentaje de empresas que analizan Big Data en sectores industriales clave. | 40 |

ÍNDICE DE TABLAS

| | |
|---|----|
| Tabla 1. Muestra de las empresas empleadas en el análisis | 18 |
| Tabla 2. Potenciales de Calentamiento Global (GWP) de los principales gases de efecto invernadero..... | 22 |

ABREVIATURAS

ANFIS: Adaptive Neuro-Fuzzy Inference Systems

ANN: Redes Neuronales Artificiales

BD: Big Data

CCS: Captura y almacenamiento de carbono

DEA: Data Envelopment Analysis

DL: Deep Learning

GEI: Gases de Efecto Invernadero

IA: Inteligencia Artificial

ICEENet: Industrial Carbon Emission Estimation Network

ML: Machine Learning

ODS: Objetivos de Desarrollo Sostenible

SVM: Support Vector Machine

1. INTRODUCCIÓN

1.1. Justificación y relevancia del tema elegido

Actualmente nos encontramos en una creciente consciencia ante las emisiones contaminantes, en especial en los sectores industriales. Las empresas pertenecientes a estos sectores son las principales contaminantes debido a los materiales que emplean en sus procesos. Industrias como las del acero, aluminio, cemento, petróleo, papel y química son necesarias para nuestra economía, aunque también contribuyen significativamente al deterioro del medioambiente. Aquí es donde surge un desafío circular que consiste en que estas empresas quieren reducir sus emisiones; sin embargo, para ello, necesitan financiación. Las autoridades y empresas no les conceden préstamos ya que contaminan y por ello se genera un desafío circular en el que no reciben ayuda y por lo tanto les resulta difícil contribuir a la mejora del medioambiente. De esta manera, acceder a esta financiación es una barrera crítica para estas industrias. Las regulaciones impuestas por los organismos controladores se están volviendo cada vez más rigurosas, lo que ha provocado que numerosas compañías tengan que dar con medidas de sostenibilidad más innovadoras y eficientes que les permitan demostrar que, efectivamente, están comprometidas con el medioambiente. Este problema influye en su actividad diaria al mismo tiempo que supone un desafío importante para industrias fundamentales en la economía y sociedad.

Antes de explorar las herramientas tecnológicas disponibles para reducir las emisiones, es necesario analizar el nivel de compromiso que las empresas de los sectores industriales más contaminantes han asumido. Este análisis nos permitirá identificar qué tan alineadas están estas industrias con los objetivos globales de sostenibilidad y, específicamente, con la meta de emisiones netas cero.

En este contexto, surge la importancia de que estas empresas industriales sepan monitorizar y controlar sus mejoras en emisiones. Aquí juegan un papel muy importante la Inteligencia Artificial y el Big Data, que permiten optimizar los procesos y tomar decisiones inteligentes relacionadas con la sostenibilidad.

Existen múltiples formas de aplicar estas herramientas con el objetivo de reducir las emisiones. Gracias a herramientas que analizaré en este trabajo, las empresas pueden emplear

y trabajar con numerosos datos en tiempo real y así reducir su huella de manera más eficiente a través de decisiones inteligentes. Asimismo, el empleo de técnicas de Big Data e Inteligencia Artificial en el control de las emisiones y en la contribución a la sostenibilidad, tienen en cuenta los Objetivos de Desarrollo Sostenible (ODS), que se proponen para la reducción de las emisiones de gases de efecto invernadero y la transición hacia economías más limpias. Esto les proporciona no solo una posibilidad de crecimiento en el corto plazo, sino también una estrategia a largo plazo para garantizar su supervivencia e importancia en un mercado que cada vez exige mayor responsabilidad ambiental.

Este trabajo está motivado por la necesidad de comprender cuál es el estado actual de los objetivos sostenibles de estas empresas y como gracias a la Inteligencia Artificial y el Big Data pueden tomar decisiones más inteligentes para lograr esta financiación para contribuir a la reducción global de emisiones de cara a los próximos años.

1.2. Objetivo principal y objetivos secundarios

El objetivo principal de este TFG es analizar cómo el uso de técnicas de Big Data e Inteligencia Artificial puede reducir las emisiones producidas por las empresas de los sectores industriales, en concreto, de aquellos sectores industriales que más contaminan y, de esta manera, contribuir a la sostenibilidad global. Asimismo, esto les ayudará a lograr esa financiación que tanto necesitan.

Este trabajo tiene también una serie de objetivos secundarios, entre los que se encuentran los siguientes:

- Identificar las herramientas de IA y Big Data más utilizadas por las empresas de los sectores industriales para reducir emisiones.
- Evaluar el impacto de la implementación de estas tecnologías en la eficiencia energética y la sostenibilidad de las empresas.
- Evaluar las tendencias en sostenibilidad de las empresas mediante el análisis de objetivos Net Zero y cobertura de emisiones en los sectores más contaminantes.

- Analizar casos específicos de empresas que han aplicado IA y Big Data para la reducción de emisiones y su impacto en la sostenibilidad.
- Examinar las barreras y desafíos éticos que enfrentan las empresas al implementar estas tecnologías.

1.3. Metodología empleada

A continuación, se ofrece un análisis de los pasos y técnicas que se emplearán a lo largo del trabajo.

1. Identificación y delimitación del problema.

Se llevará a cabo un análisis y una revisión de la literatura académica que permita identificar cuáles son aquellos sectores o industrias más relevantes. Algunos criterios serán los siguientes:

- Relevancia del sector según emisiones.
- Contribución económica a nivel global.
- Compromisos de las empresas con los objetivos sostenibles.

2. Recopilación, estructuración y agrupación de datos.

A continuación, realizamos un análisis y una recopilación de información de fuentes objetivas como informes de sostenibilidad publicados en las páginas web de cada una de las empresas representativas de cada sector. Esta información se va a estructurar en bases de datos en Excel clasificadas por sector. Cada una de estas bases de datos incluirá variables estandarizadas como objetivos Net Zero, cobertura de gases y estrategias de mitigación de emisiones (Scope 1, Scope 2 y Scope 3).

3. Visualización de los datos.

Los datos serán procesados con herramientas de programación, en este caso, con Python, para poder hacer representaciones gráficas. Para ello, emplearé librerías como “pandas”, “matplotlib” y “numpy”. De esta manera, la interpretación de los datos será mucho más sencilla y clara.

4. Análisis comparativo sectorial.

En este paso se va a hacer una comparativa entre sectores para identificar similitudes y diferencias entre los sectores, analizar los principales desafíos propios de cada industria para identificar las particularidades de cada sector, así como la necesidad de enfoques individualizados.

5. Aplicación de herramientas tecnológicas: Big Data e Inteligencia Artificial.

Finalmente, se explorará el empleo de este tipo de herramientas de tecnología innovadora que resultarán clave para resolver estos desafíos que necesitan cierta individualización y eficacia.

2. MARCO TEÓRICO

2.1. Que es la sostenibilidad y cómo se aplica en los sectores industriales

La sostenibilidad, durante muchos años, se ha definido como el crecimiento que satisface las necesidades del mundo actual sin poner en un compromiso la capacidad de las futuras generaciones para satisfacer las necesidades que puedan tener (Federal Office for Spatial Development ARE, s.f.). En el contexto industrial, la sostenibilidad implica la adopción de prácticas que minimicen el impacto en el medio ambiente, que optimicen el uso de recursos y que promuevan la responsabilidad social (Roa, 2024). Según un estudio de BBVA, el sector industrial es crucial para la economía global y enfrenta el desafío de alcanzar la neutralidad climática para el año 2050 (Roa, 2024).

La aplicación de la sostenibilidad en estas industrias se muestra presente en múltiples procesos y prácticas por parte de las empresas más relevantes de las industrias. Por ejemplo, la utilización de materiales más comprometidos con el medio ambiente y el diseño eficiente de recursos son prácticas cada vez más populares que buscan reducir la huella de carbono y emisiones (Integral Innovation Experts, 2023). Además, el análisis del ciclo vital de los productos hace que se puedan identificar aquellos procesos y áreas donde se pueda reducir al máximo los impactos ambientales, lo cual es de elevada importancia para la producción y funcionamiento sostenibles.

Un aspecto fundamental de la sostenibilidad en la industria es el respeto por las normativas ambientales. Las empresas tienen la responsabilidad de asegurarse de que sus actividades estén alineadas con las leyes ambientales actuales para evitar penalizaciones monetarias y mantener así la confianza de sus clientes. Cumplir con estas regulaciones no solo es un requisito legal, sino que también representa una oportunidad para optimizar la operación y reducir costos a largo plazo (Integral Innovation Experts, 2023).

Como señalaba Elkington (1997, p. 12) hace unos años, "future market success will often depend on an individual company's (or entire value chain's) ability to simultaneously satisfy not just the traditional bottom line of profitability but also two emergent bottom lines; one focusing on environmental quality, the other on social justice. As a result, companies and their boards will need to think in terms of the triple bottom line" [El éxito futuro en el mercado dependerá a menudo de la capacidad de una empresa individual (o de la cadena de valor completa) para satisfacer simultáneamente no sólo el resultado final tradicional de rentabilidad sino también dos resultados emergentes; uno centrado en la calidad ambiental y el otro en la justicia social. Como resultado, las empresas y sus directorios deberán pensar en términos del triple resultado final].

2.2. Big Data aplicado a la gestión de emisiones

La utilización de Big Data en la gestión de emisiones está suponiendo un avance fundamental para las industrias en su esfuerzo por reducir el impacto que tienen en el medioambiente. A través de recopilación y el análisis de grandes volúmenes de datos, las empresas pueden monitorear en tiempo real lo que consumen de energía, así como los niveles de emisión de gases contaminantes, lo que permite una respuesta de forma más efectiva a los objetivos de sostenibilidad. Según Zhou, Fu y Yang (2016), la implementación de herramientas de Big Data en el uso de energía ha permitido que las empresas tengan un mayor control de su consumo de energía y, por lo tanto, lo puedan optimizar y como consecuencia, reducir las emisiones. Este análisis continuo permite identificar patrones y áreas de ineficiencia en los procesos de estas empresas industriales, permitiendo así mejoras específicas que no solo reducen el consumo de recursos, sino también las emisiones.

Big Data permite el análisis incluso cuando existen problemas como la carencia, inconsistencia o insuficiencia de datos. Liu et al. (2024) presentan un marco basado en aprendizaje profundo que integra varias etapas para mejorar la precisión en la estimación de emisiones industriales. Este enfoque, el cual es conocido como “DI-DR-EE (Data Imputation, Device Recognition y Emission Estimation)”, incluye tres fases críticas en el monitoreo: la imputación de datos, el reconocimiento de dispositivos y la estimación de emisiones (Liu et al., 2024).

La primera etapa, denominada “Data Imputation Network (DINet)”, utiliza una técnica innovadora de percepción de super-resolución con el objetivo de conseguir recuperar datos faltantes de medidores inteligentes. Esta técnica permite reconstruir la información que se ha perdido, lo cual es crucial para mantener la exactitud en el análisis de emisiones, especialmente en escenarios donde pueden faltar hasta un 90% de los datos (Liu et al., 2024). Esto asegura que incluso en situaciones de pérdida significativa de datos, las compañías tienen la posibilidad de seguir teniendo estimaciones precisas, apoyando una toma de decisiones basada en evidencias.

La segunda etapa del marco, “Device Recognition Network (DRNet)”, utiliza convoluciones separables para identificar los estados de los dispositivos a partir de datos de baja frecuencia. Esta técnica aumenta la eficiencia en el proceso de reconocimiento de dispositivos con un mayor rendimiento computacional, lo que es fundamental para el entorno industrial, en el cual los dispositivos operan en muchos estados y requieren una revisión continua para reducir al máximo las emisiones indirectas y directas (Liu et al., 2024).

Finalmente, la tercera etapa, denominada “Industrial Carbon Emission Estimation Network (ICEENet)”, integra los datos imputados de los medidores inteligentes y la información de reconocimiento de dispositivos generada por las etapas anteriores para estimar en tiempo real las emisiones de carbono industriales. ICEENet emplea técnicas avanzadas de aprendizaje profundo que garantizan estimaciones precisas, incluso en casos en los que hay datos incompletos. Esto permite a las industrias monitorizar y gestionar sus emisiones de carbono de manera efectiva, apoyando la toma de decisiones para reducir su huella ambiental (Liu et al., 2024).

Asimismo, la integración de Big Data en la gestión de emisiones permite a las industrias no solo controlar y reducir sus emisiones, sino también optimizar sus procesos de producción. Según Hämäläinen e Inkinen (2019), utilizar grandes volúmenes de datos hace posible la identificación de fuentes de contaminación y la implementación de tecnologías limpias, lo que fomenta una producción más responsable y sostenible. La diversidad de datos analizados demuestra la complejidad de las operaciones del mercado y la responsabilidad corporativa, enfatizando la necesidad de combinar recursos de datos a nivel de unidad industrial para desarrollar herramientas más eficientes de monitoreo ambiental y toma de decisiones (Hämäläinen & Inkinen, 2019).

La capacidad de Big Data para gestionar grandes volúmenes de información en tiempo real es importante para la responsabilidad corporativa y la sostenibilidad ambiental. Hämäläinen e Inkinen (2019) destacan también que la combinación de Big Data, medición de emisiones y monitoreo activo proporciona una base sólida para la toma de decisiones en entornos operativos que se encuentran en continuo cambio. Esto no solo mejora la precisión en la gestión de emisiones, sino que también permite a las empresas adaptarse rápidamente a nuevas regulaciones y estándares ambientales, promoviendo una cultura industrial orientada hacia bajas emisiones y producción limpia (Hämäläinen & Inkinen, 2019).

Finalmente, la integración de Big Data con otras tecnologías emergentes, como la inteligencia artificial y el blockchain, está abriendo nuevas posibilidades para la gestión de emisiones. Estas tecnologías permiten una mayor transparencia y trazabilidad en la cadena de suministro, lo que es esencial para garantizar que todas las partes involucradas cumplan con los estándares de sostenibilidad (Gupta & George, 2016). La combinación de estas herramientas tecnológicas está transformando la manera en que las industrias abordan la sostenibilidad y la gestión ambiental.

2.3. IA aplicada a la reducción de emisiones

La inteligencia artificial está demostrando ser una herramienta potente en la lucha contra el cambio climático, especialmente en la disminución de emisiones de gases de efecto invernadero. Un informe reciente de PwC, en colaboración con Microsoft y el Instituto de

Cambio Medioambiental de la Universidad de Oxford, destaca cómo la IA puede ayudar a las empresas a romper el vínculo tradicional entre crecimiento económico y emisiones de carbono. Este estudio muestra que la IA puede optimizar procesos de las industrias, desarrollar la eficiencia de energía y disminuir las emisiones en sectores clave como la energía, el transporte y la industria manufacturera. Por ejemplo, un generador de acero logró disminuir su consumo energético en un 10% gracias a la implementación de IA, lo que no solo mejoró su impacto ambiental, sino también sus resultados financieros. (PwC, Microsoft, & Instituto de Cambio Medioambiental de la Universidad de Oxford, 2024).

Asimismo, se ha demostrado que las recomendaciones por parte de la IA han hecho posible controlar los cultivos y permitir una transición en el sector agrícola. Esto ha permitido disminuir la cantidad de fertilizante empleado con el objetivo de reducir las emisiones. Asimismo, la IA se está empleando para aumentar la producción de energía renovable. Un caso de estudio muestra que el análisis en tiempo real de datos de viento mediante IA permitió “aumentar un 20% la producción de energía en parques eólicos, lo que se tradujo en 425 teravatios-hora adicionales de energía limpia al año” (Cátedra BP de Medio Ambiente, 2024).

2.4. Objetivos de Desarrollo Sostenible (ODS) relacionados

El empleo de herramientas relacionadas con Big Data e Inteligencia Artificial en el control de las emisiones y la responsabilidad corporativa de las empresas industriales se encuentra estrechamente relacionado con los Objetivos de Desarrollo Sostenible (ODS), especialmente con algunos en concreto. Las empresas actualmente están empleando estas herramientas con el fin de cumplir estos objetivos de manera más eficiente.

Por ejemplo, el artículo de Vinuesa et al. (2020) proporciona una perspectiva completa sobre cómo afecta el uso de herramientas de inteligencia artificial en la consecución de los ODS. En este estudio se destaca que la Inteligencia Artificial puede tanto hacer posible como limitar el logro de los ODS, y destaca lo fundamental que es contribuir con el objetivo de garantizar un desarrollo sostenible. Asimismo, hay que tener en cuenta el impacto en las cuestiones éticas, la necesidad de diálogo global y la importancia de la diversidad en la fuerza

laboral de la inteligencia artificial. Este análisis resulta relevante para comprender el impacto de la IA en la sostenibilidad industrial.

3. DESARROLLO

3.1. Exploración datos de sostenibilidad

3.1.1. Criterios de selección de sectores y empresas analizadas

Para seleccionar los sectores y empresas que han formado parte de la muestra, me he basado en ciertos criterios. En cuanto a los sectores, he escogido aquellos que se consideran más contaminantes en cuanto a emisión de gases. Asimismo, para la selección de estos sectores, he tenido en cuenta aquellas industrias que estén comprometidas con los objetivos Net Zero. He seleccionado estos sectores porque contribuyen de forma considerable a la huella de carbono global y es de gran importancia que progresen en el proceso de transición hacia un modelo más sostenible.

La industria de acero representa aproximadamente un 7% de las emisiones de gases a nivel global (Souza Filho et al., 2022). La industria del cemento representa entre el 7 y 8 % de las emisiones globales de CO₂ (Barbhuiya et al., 2024). Por su parte, la industria del aluminio emite en torno al 2% de las emisiones (Saevarsdottir et al., 2019). La industria del papel es responsable de aproximadamente el 6% de los gases (Del Rio et al., 2022). En cuanto al petróleo, todo el proceso que conlleva su refinamiento y ciclo de vida contamina en torno a un 15%-40% de todas las emisiones globales de GEI (Masnadi et al., 2018).

En cuanto a la elección de las empresas, he elegido las compañías europeas cotizadas más grandes de los cinco sectores, y analizando si contaban con informes de sostenibilidad actualizados y si estaban comprometidas con los objetivos sostenibles.

3.1.2. Introducción al análisis y muestra empleada

La sostenibilidad se ha convertido en todo un reto, principalmente para aquellas empresas de los sectores industriales que más contaminan. Sin embargo, es importante conocer si verdaderamente están dispuestas a cumplir con este reto. Para ello, he llevado a cabo un

análisis y un estudio de los reportes de sostenibilidad más recientes de las empresas más representativas de cada uno de los sectores, a nivel global. Los sectores seleccionados son el químico, petrolero, papel, acero, cemento y aluminio.

A continuación, se muestran una tabla y un gráfico más visuales de la muestra que he utilizado en mi análisis:

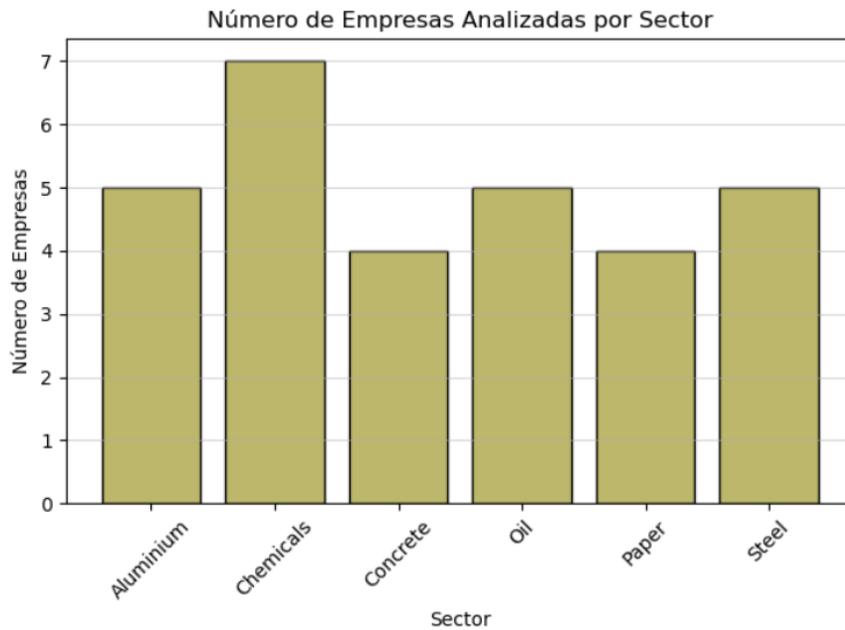
Tabla 1. Muestra de las empresas empleadas en el análisis

| INDUSTRIA | EMPRESAS DE LA MUESTRA |
|---------------------|--|
| Industria Aluminio | Norsk Hydro ASA UC Rusal Rio Tinto Group Mytilneos Constellium |
| Industria Química | BASF Air Liquide Solvay SA Evonik Industries Covestro AG |
| Industria Cemento | LafargeHolcim LTD Heidelberg Materials CRH Buzzi SpA |
| Industria Petrolera | Royal Dutch Shell BP Total Energies Equinor Repsol |
| Industria Papel | Stora Enso UPM-Kymmene (UPM) Smurfit Kappa DS Smith plc |

| | |
|-----------------|--|
| Industria Acero | Acerinox ArcelorMittal ThyssenKrupp SSAB Voestalpine |
|-----------------|--|

Fuente: elaboración propia

Ilustración 1. Número de Empresas Analizadas por Sector



Fuente: elaboración propia

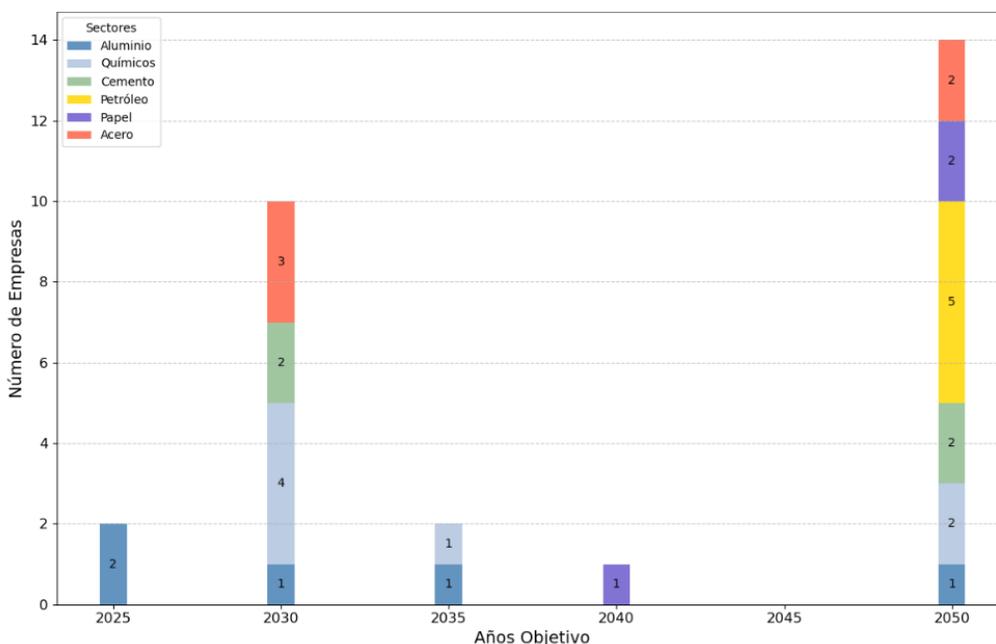
El análisis de estos informes me ha permitido extraer variables significativas de las empresas de los diferentes sectores que hacen posible llevar a cabo un entendimiento de la situación y compromiso actual de estos frente a la reducción de emisiones. Estas variables extraídas de los reportes y pasadas a bases de datos de Excel incluyen información acerca del compromiso de las empresas con el objetivo “Net Zero”, la cobertura de gases de efecto invernadero (GEI) y el alcance de sus estrategias (Scope 1, Scope 2 y Scope 3). Este análisis me ha permitido investigar cada sector y realizar una comparativa de variables determinantes.

3.1.3. Análisis Objetivos Net Zero

En estos momentos de transición, un objetivo fundamental y muy importante en el logro de esta sostenibilidad deseada es el objetivo de emisiones netas. Son muchas las empresas que cuentan con objetivos tanto a largo como a corto plazo con objetivos para alcanzar este “Net Zero target” en unos años. Para alcanzar el objetivo de Net Zero, se deben reducir tres tipos de emisiones: directas (Scope 1), indirectas por consumo energético (Scope 2) e indirectas en la cadena de valor (Scope 3). Según un estudio publicado de Meyer (2018), alcanzar las emisiones netas cero no solo representa una estrategia clave para mitigar el cambio climático, sino que también impulsa la transformación hacia una industria verde. Este enfoque promueve prácticas sostenibles dentro de las industrias para alinearse con los compromisos globales y reducir su impacto ambiental.

Los gráficos siguientes representan los años objetivo de los 3 Scope para alcanzar el objetivo Net Zero para las empresas de los seis sectores.

Ilustración 2. *Años Objetivo Net Zero*



Fuente: elaboración propia con datos de informes de sostenibilidad de las empresas seleccionadas para la muestra.

El gráfico anterior muestra la manera en la que se distribuyen los años objetivo para conseguir este objetivo Net Zero para cada sector. Del análisis de los gráficos, obtengo una serie de insights que considero influyentes para la aplicación de futuras herramientas de IA y Big Data:

- 2050 es el año que predomina. En la mayor parte de las industrias analizadas, las empresas tienen el año 2050 como objetivo para conseguir Net Zero, para así alinearse con los objetivos a nivel internacional.
- Existen metas intermedias, que no son necesariamente requeridas en el año 2050, sino antes. Aquí aparecen desafíos hacia 2030, lo que nos indica que tienen estrategias más desafiantes.
- En los sectores de cemento y papel, los objetivos se encuentran distribuidos entre metas intermedias enfocadas en 2030 y 2040 y metas más a largo plazo en 2050.
- La industria de petróleo muestra que todas las empresas tienen como objetivo exclusivo 2050 lo que sugiere que en este sector podría ser más dificultosa esta descarbonización.

El análisis muestra que el 2050 es el año más repetido entre los sectores analizados, en línea con los acuerdos y compromisos internacionales. No obstante, sectores como el aluminio, los químicos y el acero presentan metas intermedias hacia 2030 y 2035, lo que puede indicar una mayor diversificación en los plazos de transición.

3.1.4. Cobertura de gases en los diferentes sectores

Una parte fundamental para establecer las estrategias de sostenibilidad de las empresas en los sectores industrial es analizar e identificar los GEI que pretenden cubrir y mitigar en sus planes. Los múltiples sectores que he analizado son variados en cuanto a emisión de gases y tienen perfiles diferentes, lo cual se muestra en las prioridades y características de cada tipo de empresa.

En este apartado, lo que he hecho ha sido identificar cuáles son los gases más importantes para cada sector en base a los datos extraídos de los informes de sostenibilidad de las

diferentes empresas. Los gráficos presentados a continuación muestran la frecuencia con la que cada gas aparece en los informes de sostenibilidad, lo que indica cuántas empresas dentro de cada sector priorizan la reducción de cada gas en sus estrategias climáticas.

Con el fin de comprender mejor los gráficos presentados a continuación, he considerado importante ver la relación que existe entre los diferentes gases y ver así su impacto relativo. Este impacto se mide a través del Potencial de Calentamiento Global (GWP), que permite hacer una comparación del impacto de los diferentes gases en el calentamiento global. Asimismo, permite analizar la capacidad de un gas de atrapar calor en la atmósfera en relación con el dióxido de carbono (CO₂) durante 100 años (U.S. Environmental Protection Agency, 2025). A continuación, se muestra una tabla con los valores de GWP para los gases más relevantes en los sectores analizados:

Tabla 2. Potenciales de Calentamiento Global (GWP) de los principales gases de efecto invernadero.

| Gas | Fórmula | GWP (100 años) |
|----------------------------|------------------|--------------------------|
| Dióxido de carbono | CO ₂ | 1 |
| Metano | CH ₄ | 27-30 |
| Óxido nitroso | N ₂ O | Miles a decenas de miles |
| Hidrofluorocarbonos (HFCs) | Varía | Miles a decenas de miles |
| Perfluorocarbonos (PFCs) | Varía | Miles a decenas de miles |
| Hexafluoruro de azufre | SF ₆ | Miles a decenas de miles |
| Trifluoruro de nitrógeno | NF ₃ | Miles a decenas de miles |

Fuente: Elaboración propia con datos de la Agencia de Protección Ambiental de los EE. UU. (EPA) <https://www.epa.gov/ghgemissions/understanding-global-warming-potentials>.

Ilustración 3. Gases Industria Aluminio

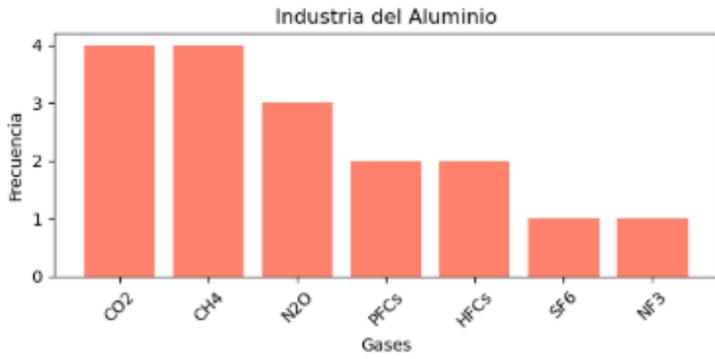


Ilustración 4. Gases Industria Química.



Ilustración 5. Gases Industria Petróleo.

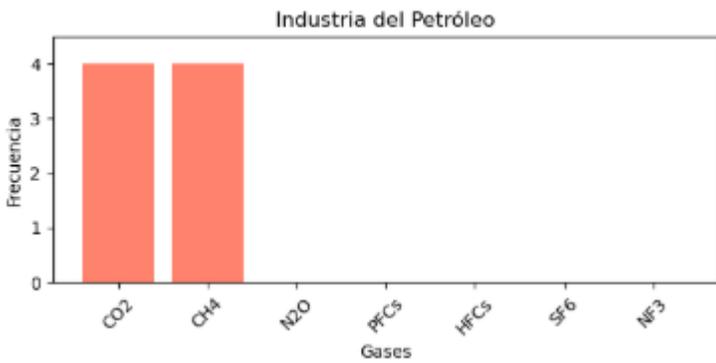


Ilustración 6. Gases Industria Cemento.

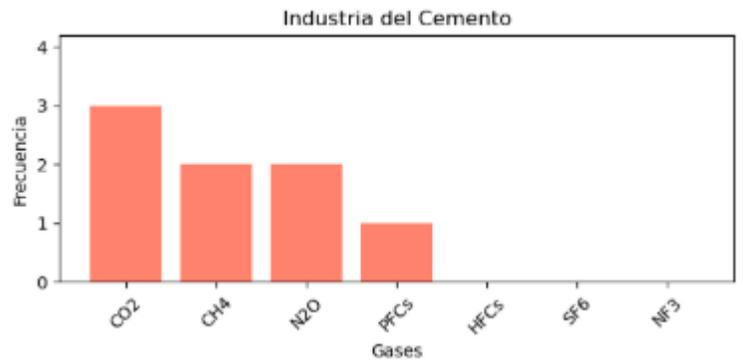


Ilustración 8. Gases Industria Papel.

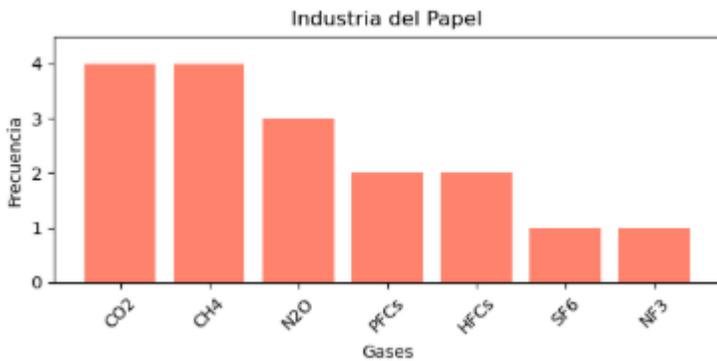
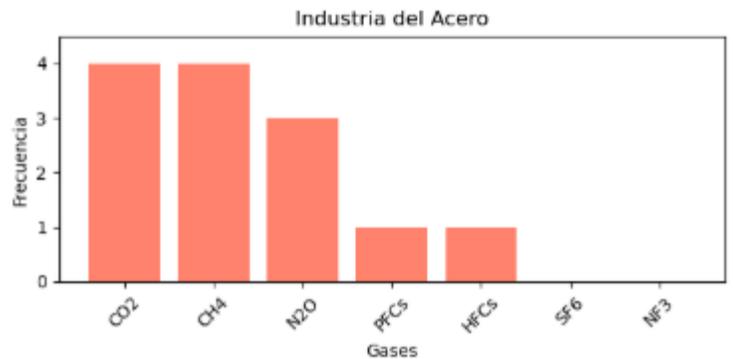


Ilustración 7. Gases Industria Acero.



Así, el análisis de estos gráficos me ha permitido obtener una serie de insights que considero importantes en mi análisis.

- Dióxido de carbono (CO₂). Este gas es el que se encuentra presente en los planes de mitigación de todos los sectores analizados, ya que su alcance engloba las emisiones totales de gases según su potencial de calentamiento global. Por lo tanto, es fundamental que las herramientas empleadas para reducir las emisiones de gases estén enfocadas en gestionar el CO₂.
- El metano (CH₄) es bastante importante en industrias como la del petróleo, la química y del acero, donde los procesos de extracción y procesamiento de los materiales utilizados contribuyen de manera significativa a sus emisiones. Este gas es un objetivo fundamental porque tiene un alto potencial de contribuir al calentamiento global en comparación con otros como el dióxido de carbono.
- La industria del cemento presenta un desafío particular por las elevadas emisiones de CO₂ generadas directamente por su proceso de producción, destacando la necesidad de tecnologías innovadoras para abordar estas emisiones. Por otro lado, la industria del papel refleja un enfoque en gases más asociados con procesos químicos y energéticos, como el N₂O.

Estos insights que he obtenido de los informes, reflejan de qué manera las diferentes industrias están centradas en reducir las emisiones de diferentes gases de efecto invernadero, adaptando sus planes y estrategias a largo plazo a las características particulares de cada sector. La diversidad de gases hace que sea necesario aplicar estrategias específicas según las necesidades de cada industria. Asimismo, la prioridad constante en la reducción del CO₂ y equivalentes refleja un compromiso generalizado con los acuerdos internacionales orientados a combatir el cambio climático.

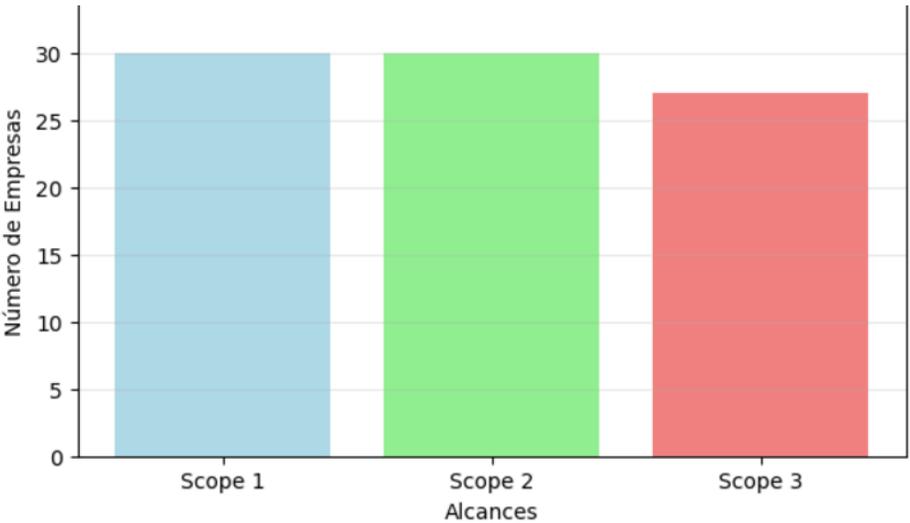
3.1.5. Planes de Transición. Compromiso de estrategias para alcanzar objetivos (Scope 1, Scope 2 y Scope 3)

Las emisiones Scope 1, 2 y 3 son términos fundamentales para entender los impactos ambientales de las empresas. El Scope 1 abarca todas aquellas emisiones directas provenientes de fuentes que son propiedad de la empresa o que están controladas por la

empresa. El Scope 2 hace referencia a las emisiones indirectas relacionadas con la generación de energía adquirida y consumida por la empresa. Finalmente, el Scope 3 abarca todas las demás emisiones indirectas que tienen lugar en todo el proceso productivo y en la cadena de valor de la empresa, como las actividades de los proveedores o el uso de los productos por parte de los consumidores. Tener una idea clara sobre estos alcances permite que se pueda establecer una metodología estructurada para gestionar las emisiones en diversos sectores, lo que hace que las diferentes compañías puedan llevar a cabo estrategias de sostenibilidad adaptadas a las necesidades específicas del sector o empresa (Teske et al., 2022).

El gráfico que he realizado muestra el número de empresas que han adoptado compromisos de sostenibilidad en cada uno de los tres alcances, según los de los informes de sostenibilidad de todas las empresas. En el Scope 1, se observa que 30 empresas (el 100% de la muestra) han establecido compromisos claros. Lo mismo ocurre con el Scope 2. Sin embargo, el Scope 3 muestra un nivel de compromiso menor, con 27 empresas. Esta diferencia destaca cómo el tercer alcance plantea mayores desafíos en términos de medición y control.

Ilustración 9. Cobertura de Compromisos en Alcances (Scope 1, 2 y 3).



Fuente: Elaboración propia con base en informes de sostenibilidad empresariales.

Este análisis que he llevado a cabo de los diferentes alcances y el nivel de compromiso que muestran las empresas hacia ellos permite extraer varias conclusiones clave. En primer lugar, podemos observar que las empresas están más comprometidas con reducir las emisiones del Scope 1 (emisiones directas de la actividad) y del Scope 2 (las que se generan de la energía adquirida). En el caso del Scope 3 (el resto de las emisiones indirectas procedentes de toda la cadena de suministro), aunque muchas empresas han comenzado a mostrar su compromiso para mitigar las emisiones, es el que menos compromiso refleja a nivel general. Esto nos indica que probablemente se deba a que estas emisiones del tercer alcance son bastante más difíciles de monitorear y de controlar, ya que tienen lugar en todo el proceso de producción y consumo. Asimismo, es importante entender que muchas veces, para controlar estas emisiones, existen mayores limitaciones técnicas y de colaboración que supone depender muchas veces de terceros en los objetivos de sostenibilidad.

Por otro lado, es importante tener en cuenta que, para lograr gestionar el Scope 3 de forma eficiente, será necesario implementar tecnologías avanzadas como la Inteligencia Artificial y el Big Data. Este análisis subraya la necesidad de desarrollar estrategias integrales para abordar los desafíos específicos del Scope 3, asegurando una transición más eficiente hacia los objetivos de sostenibilidad a nivel global.

3.1.6. Obtención datos Big Data por sector

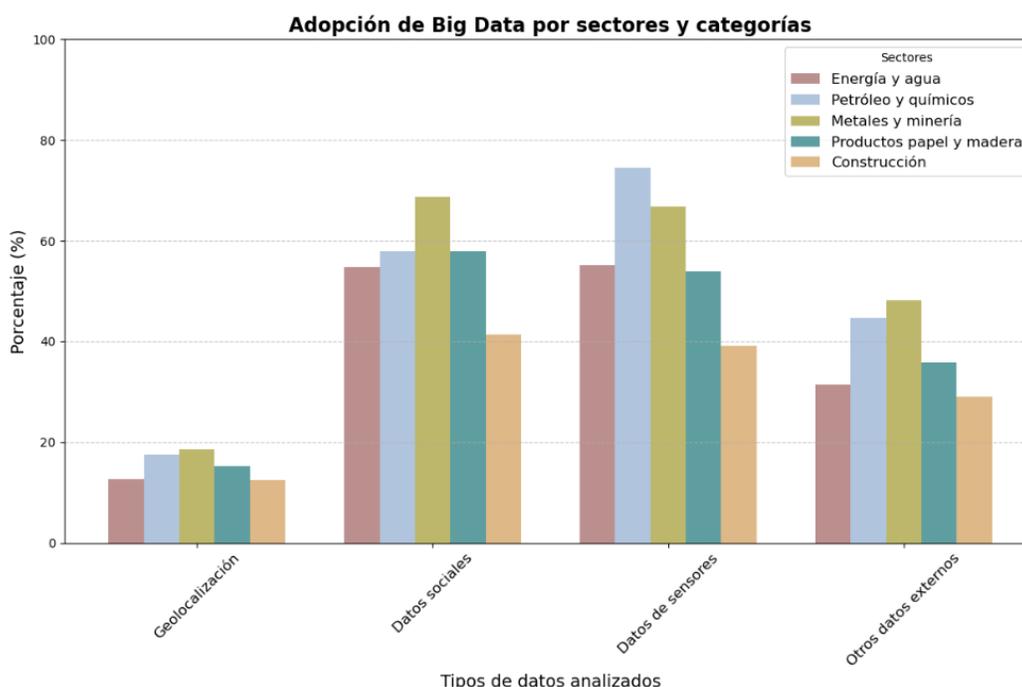
Como parte de la exploración de los datos de sostenibilidad, es relevante analizar cómo algunos sectores industriales clave utilizan herramientas de Big Data. La Figura 3.1 muestra cómo algunos de los sectores que estoy analizando, entre otros, como energía, petróleo y químicos, y metales y minería, papel y madera están adoptando estas tecnologías para procesar datos como geolocalización, sensores y otros datos externos (Instituto Nacional de Estadística, 2021). Estos datos ofrecen un contexto preliminar sobre la adopción del Big Data en sectores industriales, lo que se analizará en detalle en el apartado 3.3, enfocado en el monitoreo de emisiones.

Aunque los datos del Instituto Nacional de Estadística (Instituto Nacional de Estadística, 2021) presentan fundamentalmente la realidad del contexto español, su análisis ofrece una

perspectiva que puede proporcionar insights para identificar patrones generales en la adopción de tecnologías de BD en sectores industriales clave. Aunque es cierto que existen limitaciones en cuanto a la representatividad de los datos para empresas internacionales, este enfoque comparativo permite exponer los patrones y tendencias que se pueden extrapolar al resto de empresas del mundo.

Así, el análisis que muestro en la Ilustración 10 ayuda a entender de qué manera algunas empresas están empleando determinadas técnicas de Big Data como geolocalización, sensores y datos externos, para una mayor eficiencia en la sostenibilidad.

Ilustración 10. Adopción de Big Data por sectores y categorías.



Fuente: elaboración propia con datos del Instituto Nacional de Estadística.

De acuerdo con los datos representados, los sectores con mayor adopción de tecnologías de Big Data son petróleo y químicos y metales y minería, especialmente en el análisis de datos sociales (57,85 % y 68,72 %, respectivamente) y de sensores (74,50 % y 66,88 %, respectivamente) (Instituto Nacional de Estadística, 2021). Esto se debe a la necesidad de optimizar procesos altamente complejos y reducir emisiones en estos sectores intensivos en energía y recursos (Instituto Nacional de Estadística, 2021).

Por otro lado, sectores como productos papel y madera y construcción presentan un menor porcentaje de adopción, particularmente en el uso de datos de geolocalización y otros datos externos, con valores inferiores al 36 % (Instituto Nacional de Estadística, 2021). Esto sugiere la existencia de barreras específicas en la implementación de estas tecnologías, como la falta de inversión en infraestructura tecnológica o limitaciones en la capacitación de personal especializado (Instituto Nacional de Estadística, 2021).

Los datos analizados, extraídos del Instituto Nacional de Estadística (Instituto Nacional de Estadística, 2021), destacan la importancia de adaptar las estrategias de BD según las características y necesidades de cada sector para maximizar su impacto en la sostenibilidad y competitividad empresarial.

3.2. Diferencias y barreras en la sostenibilidad sectorial

Tras analizar los datos de sostenibilidad que he representado gráficamente y los objetivos que pretenden cumplir los distintos sectores industriales en el apartado anterior, es importante identificar las características concretas y retos de cada sector. Estas diferencias no solo muestran las necesidades particulares de cada industria, sino que también condicionan la adopción e implementación de herramientas tecnológicas avanzadas, como Big Data e Inteligencia Artificial. Entender estas características propias de cada sector, es fundamental para proponer soluciones tecnológicas adaptadas y efectivas, lo que se desarrollará en los apartados siguientes.

Este cumplimiento necesario con los diferentes objetivos Net Zero hace que los problemas surgidos para cada sector sean diferentes, dependiendo de los procesos productivos y de la cadena de valor propios de cada uno de ellos. Asimismo, la regulación juega un papel importante, variando por zona geográfica y por sector. Esta sección busca comparar las estrategias y compromisos de sostenibilidad de los diferentes sectores industriales en los que me he centrado, resaltando las barreras y diferencias que conviene tener en cuenta a la hora de implementar estrategias para cumplir con los objetivos Net Zero y reducir las emisiones de gases de efecto invernadero (GEI). En este marco, es clave analizar como los diferentes sectores industriales (aluminio, papel, petróleo, acero, cemento y químico) están dispuestos a cumplir con los objetivos Net Zero. Además, las herramientas de

IA y Big Data que analizaré posteriormente pueden desempeñar un papel clave para superar barreras que puedan surgir.

3.2.1. Análisis de las diferencias y barreras en el sector del Aluminio.

El sector del aluminio enfrenta una creciente presión para alinearse con los compromisos ambientales y las metas de sostenibilidad globales. Según los datos analizados en este trabajo, hemos visto que las empresas del sector muestran un compromiso importante con los diferentes alcances para conseguir reducir las emisiones. Este compromiso es especialmente relevante dado que el aluminio es el segundo metal más consumido a nivel mundial, y su producción primaria se realiza a través del procedimiento de Hall-Héroult, el cual sigue siendo altamente intensivo en energía y emisor de CO₂ (Padamata et al., 2021).

No obstante, las empresas del sector de aluminio no dejan de encontrar barreras que ralentizan este compromiso que muestran. Una de las barreras más relevantes es la dependencia de los recursos no renovables y los altos costos energéticos asociados con la producción primaria. Esto ha impulsado la adopción de la producción secundaria de aluminio, la cual podría reducir hasta un 93% las emisiones de CO₂ en comparación con la producción primaria (Padamata et al., 2021).

La producción primaria del aluminio se realiza a partir de la bauxita mediante dos etapas: la obtención de aluminio a través del proceso Bayer y su posterior transformación en aluminio metálico mediante electrólisis. Este proceso implica un consumo energético muy elevado y genera emisiones significativas de CO₂ y gases fluorados. En cambio, la producción secundaria se basa en el reciclaje del aluminio al final de su vida útil, y requiere solo alrededor del 5% de la energía utilizada en la producción primaria, con una consecuente reducción drástica de las emisiones asociadas (Ministerio para la Transición Ecológica y el Reto Demográfico, 2022).

No obstante, la producción secundaria enfrenta desafíos técnicos, como la necesidad de separar y refinar el aluminio reciclado para eliminar impurezas como hierro, magnesio y cobre, que afectan la calidad del producto final. Aún no ha sido posible encontrar un material alternativo al aluminio reciclado que, aparte de cumplir con los estándares técnicos

requeridos (resistencia, ligereza y conductividad), pueda ser producido y utilizado a gran escala industrial, lo cual representa un desafío clave (Padamata et al., 2021).

Además, la gestión de los subproductos, como las escorias de sal generadas durante el proceso de reciclaje, representa un desafío ambiental significativo ya que estas escorias son clasificadas como residuos peligrosos y requieren tratamientos específicos para evitar su acumulación en vertederos y su implementación es bastante costosa y compleja (Padamata et al., 2021)

Por otro lado, las políticas industriales y regulatorias juegan un papel crucial en la evolución de este sector. En regiones como Europa, iniciativas como el Pacto Verde Europeo están impulsando cambios hacia la economía circular, promoviendo el reciclaje y la reutilización del aluminio como una estrategia clave para reducir el consumo de recursos primarios (Benito & Meyer, 2024). Sin embargo, la falta de coordinación global y las disparidades entre las políticas locales dificultan la adopción uniforme de estas prácticas, creando tensiones entre los objetivos ambientales y los intereses económicos de las empresas multinacionales.

3.2.2. Análisis de las diferencias y barreras en el sector Químico.

De acuerdo con los datos previos analizados en este trabajo, el sector químico muestra un alto grado de compromiso con la implementación de prácticas sostenibles, especialmente en áreas relacionadas con la gestión de residuos y la mejora de la eficiencia energética.

Las barreras para lograr una transición hacia la sostenibilidad en el sector químico son diversas y complejas. Según McKim (2018), los principales obstáculos se agrupan en tres categorías: económicos, tecnológicos y políticos. Económicamente, la inversión en tecnologías sostenibles choca con el alto coste de las infraestructuras existentes, diseñadas para procesos tradicionales, lo que dificulta la integración de nuevas alternativas. Tecnológicamente, la "inercia tecnológica" limita la capacidad de innovación, dado que las empresas tienden a optimizar procesos existentes en lugar de apostar por desarrollos disruptivos que puedan mejorar la sostenibilidad. Además, la falta de métricas estandarizadas dificulta la evaluación del impacto ambiental y la adopción de tecnologías más limpias (McKim, 2018).

Además, las barreras regulatorias y políticas también juegan un papel crítico. En algunas zonas, la ausencia de una legislación específica y rígida hace que sea más complicada la implantación de iniciativas relacionadas con la reutilización y el reciclaje. Según el artículo de Sellitto (2018), las cooperativas y los municipios pueden desempeñar un papel importante en la recolección y clasificación de residuos para apoyar la sostenibilidad en la industria química. Sin embargo, la falta de coordinación entre actores públicos y privados limita el potencial de estas iniciativas.

A pesar de estos desafíos, el sector químico tiene la oportunidad de liderar en innovación sostenible. Invertir en infraestructura moderna, promover estándares regulatorios claros y fomentar colaboraciones público-privadas son pasos esenciales para superar estas barreras y avanzar hacia un modelo más sostenible (Sellitto, 2018).

3.2.3. Análisis de las diferencias y barreras en el sector del Cemento.

La industria del cemento enfrenta retos significativos en su camino hacia la descarbonización, ya que representa entre el 7 y 8 % de las emisiones globales de CO₂ (Barbhuiya et al., 2024). Este impacto se debe principalmente al proceso de calcinación del clínker, en el cual el carbonato de calcio se descompone a altas temperaturas, dando lugar a grandes cantidades de CO₂, además del uso de combustibles fósiles como fuentes de energía en los hornos de producción (Barbhuiya et al., 2024). Estos procesos son responsables del 90% de las emisiones de carbono en este sector (Griffiths et al., 2023).

Haciendo referencia a las barreras económicas existentes, es importante mencionar los elevados costos asociados con la implementación de tecnologías de captura y almacenamiento de carbono (CCS) y la transición hacia cementos de menores emisiones, como los cementos basados en clínkeres alternativos o materiales suplementarios (Griffiths et al., 2023). En cuanto a las barreras tecnológicas, los desafíos incluyen el bajo nivel de preparación tecnológica de alternativas más sostenibles. Esto significa que muchas alternativas más sostenibles, como los cementos con materiales suplementarios o de menor huella de carbono, aún no cuentan con un grado de desarrollo tecnológico suficiente para ser aplicadas eficazmente a gran escala y una falta de infraestructura para conseguir implementar

soluciones como el reciclaje de agregados y los procesos de economía circular (Barbhuiya et al., 2024).

Además, las barreras políticas y sociales también desempeñan un papel crucial. No existen caso y regulaciones uniformes y la resistencia al cambio dentro del sector hace que sea más complicado adoptar estas medidas sostenibles. Por ejemplo, aunque existen iniciativas como la electrificación parcial de los procesos, esta transición enfrenta desafíos como la infraestructura insuficiente y la necesidad de estándares a nivel global para su implementación efectiva (Barbhuiya et al., 2024).

A pesar de estos obstáculos, las estrategias identificadas, como la utilización de combustibles alternativos y la incorporación de cementos de bajo carbono, ofrecen oportunidades significativas para la mitigación de emisiones. La cooperación entre los sectores público y privado será clave para superar estas barreras y avanzar hacia un modelo más sostenible (Griffiths et al., 2023).

3.2.4. Análisis de las diferencias y barreras en el sector del Petróleo.

La industria del petróleo, como las demás, hace frente a desafíos significativos en su transición hacia la descarbonización, debido a su elevada contribución a las emisiones globales de GEI. Según Meyer (2018), esta industria es una de las que más emisiones de carbono genera. Esto ocurre por sus procedimientos de extracción, refinamiento y de combustión de sus productos finales. Uno de los principales desafíos es la implementación de tecnologías de captura y almacenamiento de carbono (CCS) y la electrificación de procesos industriales, lo que requiere grandes inversiones de capital y avances tecnológicos sustanciales.

Por otra parte, el informe destaca la necesidad de desarrollar políticas públicas que favorezcan la transición energética, como incentivos fiscales para la adopción de tecnologías limpias y regulaciones que fomenten la innovación. Sin embargo, estas medidas se ven limitadas por barreras económicas y sociales, como la falta de aceptación pública de nuevos

proyectos de infraestructura de CCS y la incertidumbre sobre la viabilidad económica a largo plazo de estas tecnologías (Meyer, 2018).

Adicionalmente, Chrysikopoulos et al. (2024) identifican que las empresas petroleras están empezando a incorporar mecanismos como los certificados de energía renovable (RECs) y los acuerdos de compra de energía (PPAs), que les permiten reducir su huella de carbono. No obstante, estas estrategias también enfrentan desafíos relacionados con la falta de marcos regulatorios claros en muchos mercados y la necesidad de cooperación internacional para asegurar su implementación efectiva.

3.2.5. Análisis de las diferencias y barreras en el sector del Papel.

La industria del papel es una de las industrias que más contamina a nivel mundial. Para ser concretos, constituye en torno a un 6% del consumo de energía a nivel global y es responsable de emitir casi un 2% de las emisiones de dióxido de carbono (Del Rio et al., 2022). Además, esta industria es considerada poco sostenible con el medioambiente ya que supone un daño bastante elevado tanto para la naturaleza como para los animales, principalmente los acuáticos. Esto es porque la creación de papel necesita mucha cantidad no solo de agua, sino también de materias primas. Esto se debe a la cantidad de madera que requiere ser quemada (Del Rio et al., 2022).

Como en la mayoría de las industrias que he ido analizando en mi trabajo, esta industria presenta desafíos en la transición hacia procedimientos que consuman menos energía y que sean más sostenibles con el medioambiente. Las principales barreras que conviene tener en cuenta son las tecnológicas, económicas y políticas. Más concretamente, estos desafíos son mayoritariamente debidos a la falta de una regulación sólida a nivel global y tener que depender de ciertas tecnologías que impiden innovar y ser disruptivas a las empresas de la industria. Es importante destacar también las grandes cantidades de inversión que se requieren para poder llevar a cabo alternativas como la captura y almacenamiento de carbono (CCS) (Del Rio et al., 2022). Todo ello contribuye a que las empresas líderes en este sector se resistan a llevar a cabo procesos más limpios.

Sin embargo, aunque estas barreras pueden parecer desmotivadoras, son muchas las oportunidades que tiene la industria del papel a la hora de reducir las emisiones de carbono a nivel global. Recientemente, se ha vuelto muy popular la adopción de biorefinerías y una mayor eficiencia en el uso de materias primas. Estas estrategias, unidas a una regulación firme y estable, tienen el potencial necesario para que la transición en las empresas de la industria de papel sea posible (Del Rio et al., 2022).

3.2.6. Análisis de las diferencias y barreras en el sector del Acero.

El sector del acero tampoco se queda atrás en el ranking de emisiones globales de CO₂, siendo el responsable del 7% del total de emisiones a nivel global. Esto hace que sea un foco clave a la hora de alcanzar la neutralidad climática (Souza Filho et al., 2022). En la industria del acero, uno de los procesos que más emisiones produce es la reducción del mineral del hierro. Por ello, para este procedimiento, se ha comenzado a proponer el hidrógeno como sustituto del carbono. Sin embargo, llevar a cabo esta transición de un gas a otro no es tan sencillo e implica múltiples desafíos. Estos desafíos muestran problemas como las altas temperaturas que son necesarias para realizar la transformación y el elevado consumo de energía requerido en el proceso (Souza Filho et al., 2022).

Desde una perspectiva tecnológica, es importante considerar lo complicado que es en ocasiones la integración de la tecnología necesaria. Para usar hidrógeno verde, es necesaria la transición tecnológica desde hornos cuyo principal reductor es el coque, hasta hornos que permitan el empleo de hidrógeno verde. Estrategias como la reducción a través de hidrógeno o la captura y almacenamiento de carbono (CCS) siguen planteando desafíos relacionados con la escalabilidad y la eficiencia en los procesos (Souza Filho et al., 2022).

Centrándonos en el aspecto económico, emplear técnicas con hidrógeno verde supone un elevado coste que no todas las empresas son capaces de asumir. Lo mismo ocurre con el presupuesto necesario para la infraestructura adaptada. Asimismo, la transición hacia una estrategia de producción sostenible requiere un desembolso considerable en investigación y desarrollo, al igual que incentivos regulatorios que faciliten la transición.

4. IMPACTO DE LA INTELIGENCIA ARTIFICIAL Y EL BIG DATA EN LA SOSTENIBILIDAD INDUSTRIAL

4.1. El papel de la IA y BD en la superación de barreras sectoriales

El empleo de herramientas que incorporan tecnologías como el Big Data y la Inteligencia Artificial (IA) en los sectores industriales intensivos en carbono ha reflejado ser una herramienta fundamental para llevar a cabo la transición hacia la sostenibilidad y la descarbonización. Sin embargo, el proceso de adquirir y de incorporar estas tecnologías presenta muchos problemas técnicos y en las organizaciones. Según Rodrigo et al. (2021), en su análisis sobre el desarrollo del BD e IA en la industria energética chilena, estas herramientas ofrecen beneficios significativos, como la optimización de procesos y la mejora en la eficiencia energética, pero también enfrentan problemas que no deben ser ignorados. Entre estos, destacan la falta de infraestructura tecnológica óptima, la necesidad de personal entrenado y los desafíos en la integración de sistemas tan complejos.

En este contexto, los sectores industriales más contaminantes que he analizado, como el acero, el cemento o el petróleo, pueden encontrar barreras que sean similares a las identificadas por Rodrigo et al. (2021). Sin embargo, a pesar de estas barreras, la incorporación de estas tecnologías no solo permite a las empresas reducir sus emisiones de gases, sino que además les ofrece una ventaja competitiva en un mercado que exige cada vez más sostenibilidad y responsabilidad ambiental (Rodrigo et al., 2021). Este análisis resalta la importancia de abordar los desafíos asociados a estas tecnologías para garantizar su implementación efectiva, contribuyendo a la transición hacia una economía más verde.

El estudio "Artificial Neural Network Modeling and Optimization of Hall-Heroult Process for Aluminum Production" (Sadighi et al., 2015) hace un análisis de cómo las Redes Neuronales Artificiales (ANN) y los Algoritmos Genéticos pueden optimizar el proceso Hall-Héroult que he mencionado anteriormente en mi trabajo. Como he explicado, este proceso consume mucha energía. Sadighi et al. (2015) establecen que estas redes permiten identificar las configuraciones óptimas para el proceso de producción de aluminio. Esto hace que se reduzcan considerablemente las ineficiencias operativas en las empresas y por ello, disminuir la huella de carbono de las empresas del sector de aluminio. Asimismo, los modelos de ANN

permiten una mayor pureza en el aluminio que se produce, lo cual hace que el material que desecha sea menor, y con ello, se contribuye a la sostenibilidad (Sadighi et al., 2015).

Por su parte, haciendo referencia al sector químico, el artículo "Sustainability implications of artificial intelligence in the chemical industry: A conceptual framework" de Liao et al. (2022) ofrece un análisis de cómo el empleo de IA en las empresas químicas hace posible una transición más rápida hacia la sostenibilidad. Gracias a la aplicación de IA en la optimización y control de los procedimientos químicos, las emisiones de los GEI se pueden reducir. Asimismo, es posible disminuir el porcentaje de materiales peligrosos que se utilizan en todo el proceso. Esto hace que los residuos no sean tan dañinos. Tanto la automatización como la toma de decisiones basada en IA, hace posible que la transición de las empresas sea más rápida (Liao et al., 2021). Un ejemplo es el empleo de Machine Learning para prever las reacciones químicas y llevar a cabo un uso más eficiente de los recursos empleados. Algo similar ocurre gracias a las redes neuronales artificiales, que permiten hacer una predicción del rendimiento de los procesos en la industria química. Por último, los modelos predictivos de IA permiten controlar las emisiones en tiempo real y por ello, ver en que fases del proceso productivo tiene lugar el mayor número de emisiones. Lo mismo ocurre con la detección de fugas de gases peligrosos, contribuyendo así a un proceso más seguro (Liao et al., 2022).

Tal y como se menciona en el artículo "Using Intelligent Models to Predict Weight Loss of Raw Materials During Cement Clinker Production" de Boukhari (2020), el empleo de IA es fundamental en el sector del cemento. Se han utilizado modelos de redes neuronales artificiales (ANN) optimizadas con algoritmos genéticos (GA-ANN), máquinas de soporte vectorial (LS-SVM), sistemas neuro difusos adaptativos (ANFIS) y árboles de regresión (RTE) para predecir la pérdida de peso de las materias primas en la producción de clínker de cemento (Boukhari, 2020). Esto es muy importante, ya que, como menciona Boukhari (2020), a la hora de producir clínker (componente principal del cemento), el peso de materias que se pierde en el proceso se utiliza como indicador de la calidad que tiene el producto final. Esto hace que las empresas de este sector sean más sostenibles en cierto modo ya que esto permite reducir el volumen de recursos que se desperdician.

Respecto al sector petrolero, son varias las técnicas de IA que se han llevado a cabo en este sector. Por ejemplo, en el artículo "Review of application of artificial intelligence

techniques in petroleum operations” se menciona que se han utilizado redes neuronales artificiales (ANN) para predecir la producción de hidrocarburos con mayor precisión, optimizando la extracción y reduciendo desperdicios (Bahaloo et al., 2023). Asimismo, modelos de aprendizaje automático como Support Vector Machines (SVM) hacen posible prever pérdidas de circulación durante el proceso de perforación, reduciendo así costes en la producción y reduciendo los tiempos de inactividad (Bahaloo et al., 2023). Métodos como los Adaptive Neuro-Fuzzy Inference Systems (ANFIS) han permitido estimar propiedades del subsuelo como permeabilidad y porosidad sin necesidad de pruebas físicas cuyo coste sea muy elevado (Bahaloo et al., 2023). En términos de sostenibilidad, la IA ha sido aplicada en la optimización de la inyección de CO₂ en yacimientos agotados, mejorando la eficiencia del almacenamiento de carbono y reduciendo emisiones (Bahaloo et al., 2023).

Haciendo referencia a las barreras y desafíos mencionados anteriormente del sector del papel, es importante conocer como la Inteligencia Artificial y Big Data pueden ayudar a mitigar el impacto de la contaminación por parte de las empresas de la industria del papel. Jauhar et al. (2024) demostraron de qué manera se puede mejorar la eficiencia en el medioambiente gracias a técnicas de Deep Learning (DL) y de Data Envelopment Analysis (DEA). Estas técnicas han hecho posible que las empresas puedan medir el impacto ambiental que tienen, especialmente en las fábricas de papel. Los indicadores que más se tienen en cuenta a la hora de medir este impacto son generalmente el uso de energía, agua, emisiones de CO₂, la cantidad de materia prima que se usa y los residuos contaminantes o tóxicos para el medioambiente (Jauhar et al., 2024). Esto permite no solo analizar que empresas son las más contaminantes, sino en qué fases del proceso se produce un mayor desperdicio de residuos o una mayor emisión de gases. Asimismo, técnicas de ML han hecho posible la optimización de la energía que se consume a la hora de fabricar el papel. Modelos de Redes Neuronales Artificiales (ANN) y RNN-LSTM permiten estimar la demanda de energía y ayudan a optimizar su uso. Además, permiten modificar las operaciones en tiempo real con el fin de reducir al momento la emisión de gases y el desperdicio de residuos (Jauhar et al., 2024).

Un aspecto que considero que conviene resaltar es la forma en la que los modelos de DL (RNN-LSTM), permiten predecir errores en la maquinaria. Esto no solo permite evitar

tiempos de inactividad, sino que además permite reducir el consumo de energía y ser más eficientes. A través de técnicas de IA, es posible identificar qué combinaciones de insumos y procesos generan menos residuos y consumen menos energía, así como calcular qué fábricas cumplen mejor con los objetivos de sostenibilidad y cuáles necesitan cambiar sus procesos (Jauhar et al., 2024).

Por último, en cuanto al sector del acero, son varias las aplicaciones de la IA y de BD. Kim et al. (2022) explican en el artículo “Recent advances of artificial intelligence in manufacturing industrial sectors: A review” que, tanto técnicas de ML como de DL, permiten optimizar los procesos en el sentido de mejorar el consumo de energía, evitando el consumo innecesario de energía a la hora de fabricar el acero. Cuando se produce hierro, la IA hace posible el ajuste de los parámetros para conseguir eficiencia en los procesos y minimizar las emisiones de carbono, ya que estas suelen ser bastante elevadas en el momento de reducción del mineral de hierro (Kim et al., 2022). Además, como ya he mencionado en algunos de los sectores, la IA permite analizar datos de consumo energético en tiempo real en las diferentes etapas del proceso y con ello predecir las emisiones. Esto permite tomar decisiones basadas en datos para reducir la huella de carbono en la fabricación de acero (Kim et al., 2022). Otra aplicación de IA en el sector del acero es en el funcionamiento de los hornos. Los hornos de la industria del acero consumen una gran cantidad de energía y la IA permite ajustar la temperatura y la distribución de calor de tal manera que el consumo sea el óptimo (Kim et al., 2022).

4.2. BD e IA para el monitoreo de emisiones

Monitorear las emisiones de gases se ha vuelto en una tarea fundamental para aquellas empresas que más contaminan. Para que las empresas alcancen los objetivos sostenibles (como el objetivo Net Zero), no basta únicamente con que estén comprometidas, sino que además es necesario que dispongan de las herramientas tecnológicas adecuadas y avanzadas que les permitan gestionar y reducir estas emisiones de gases de efecto invernadero de manera eficiente. En este ámbito, es donde aparece el Big Data como respuesta a múltiples desafíos y problemas que puedan surgir en el monitoreo de gases. Esta reciente tecnología permite analizar muchos datos en tiempo real y por ello, ofrecer una visión general e integral

de los datos de las empresas y ver de manera más efectiva donde puede haber ciertas ineficiencias o en qué puntos del proceso operativo se emite mayor número de gases. Asimismo, el Big Data permite analizar ciertas tendencias para llevar a cabo previsiones. Como se ha explicado en el análisis sectorial (apartado 3), cada industria presenta barreras concretas para la adopción de tecnologías sostenibles, y el Big Data es una herramienta versátil que puede adaptarse a estas particularidades para impulsar cambios significativos.

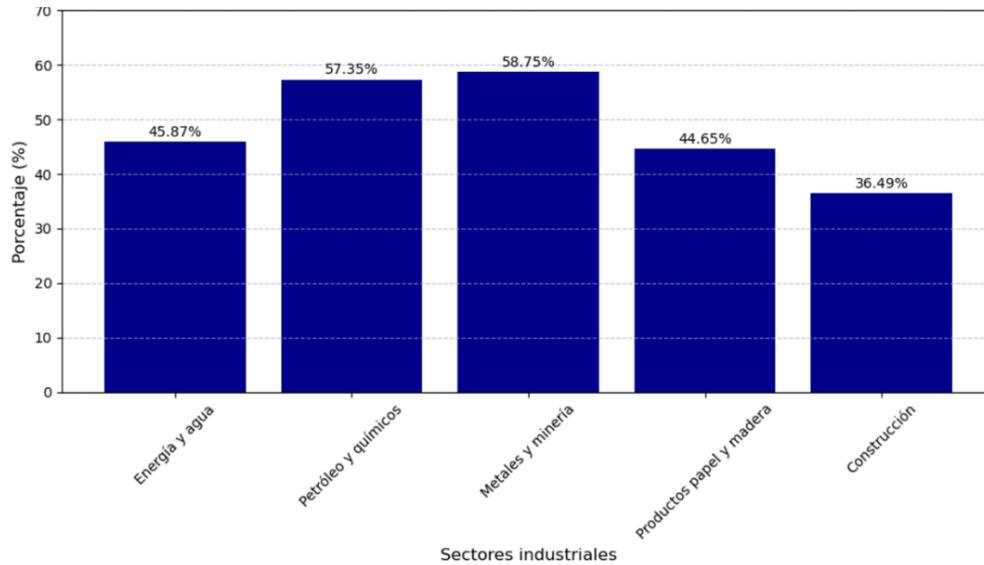
En este apartado, lo que pretendo es ofrecer un análisis de cómo el Big Data ayuda en cierta manera a monitorizar las emisiones de las empresas y a gestionar los datos en este contexto de manera efectiva. A través de casos de estudio y un análisis de la literatura, voy a poder ofrecer una visión de posibles alternativas que las empresas pueden adoptar a la hora de buscar soluciones.

El Big Data se ha consolidado como una herramienta esencial para mejorar la eficiencia operativa y la sostenibilidad en sectores industriales clave. Sin embargo, su adopción no ha sido uniforme entre los diferentes sectores, como se muestra en la Ilustración 11. Según datos del Instituto Nacional de Estadística (2021), los sectores de metales y minería (58,75 %) y petróleo y químicos (57,35 %) se presentan como líderes en la implementación de estas tecnologías, reflejando su potencial para optimizar procesos complejos y reducir emisiones.

Por otro lado, sectores como la construcción (36,49 %) y los productos de papel y madera (44,65 %) ofrecen porcentajes significativamente más bajos de adopción (Instituto Nacional de Estadística, 2021). Estas diferencias destacan la necesidad de iniciativas específicas para fomentar la digitalización en sectores con menor desarrollo tecnológico, especialmente aquellos con alta emisión de gases de efecto invernadero.

Este análisis evidencia cómo la integración del Big Data varía en función de las características operativas y económicas de cada industria, alineándose con los hallazgos previos sobre las barreras sectoriales abordadas en el apartado 3.2.

Ilustración 11. *Porcentaje de empresas que analizan Big Data en sectores industriales clave.*



Fuente: elaboración propia a partir de datos del Instituto Nacional de Estadística (2021).

El uso de Big Data ha transformado notablemente la capacidad de las empresas para abordar los desafíos medioambientales, principalmente a la hora de controlar y reducir las emisiones. Según Hämäläinen e Inkinen (2019), Big Data permite a las industrias combinar datos sobre producción, economía y emisiones para crear un panorama completo de las operaciones. Esta integración facilita la identificación de fuentes de contaminación, lo que resulta en una producción más sostenible. Por ejemplo, el análisis de datos en tiempo real y las bases de datos escalables permiten no solo registrar emisiones actuales, sino también prever tendencias y diseñar estrategias efectivas para la reducción de gases contaminantes.

Asimismo, la utilización de sensores avanzados y sistemas de monitoreo continuo permite obtener información crítica que, al ser procesada con algoritmos especializados, mejora la precisión en la toma de decisiones. Esto es especialmente importante en industrias que operan bajo el “principio 24/7”, donde el volumen de datos generados puede ser abrumador si no se cuenta con herramientas avanzadas para su análisis (Hämäläinen e Inkinen, 2019). Por lo tanto, el BD no solo actúa como una herramienta para entender procesos existentes, sino también como un catalizador para el desarrollo de tecnologías limpias y la mejora de la responsabilidad corporativa.

El Big Data, en combinación con tecnologías innovadoras como el Internet de las Cosas (IoT) y el aprendizaje automático, está modificando los modelos de monitoreo y predicción de emisiones. Según Gangwar et al. (2023), estas tecnologías permiten recolectar datos en tiempo real mediante sensores inteligentes, almacenarlos en plataformas escalables y procesarlos mediante algoritmos avanzados para realizar análisis predictivos y optimizar procesos. Por ejemplo, el uso de herramientas como Apache Hadoop y MapReduce facilita el manejo eficiente de grandes volúmenes de datos de emisiones, mientras que algoritmos de aprendizaje profundo, como las redes neuronales recurrentes (LSTM), mejoran la capacidad de prever tendencias futuras en las emisiones.

Además, el artículo destaca cómo la integración de datos meteorológicos con información de emisiones, utilizando modelos *como support vector regression (SVR) y random forest regression (RFR)*, ha demostrado una precisión del 99% en algunos casos. Esto pone de manifiesto el potencial del Big Data no solo para medir emisiones actuales, sino también para prever escenarios futuros y diseñar estrategias más efectivas de reducción de gases contaminantes (Gangwar et al., 2023).

Como he mencionado a lo largo de mi análisis, el monitoreo de emisiones de gases de efecto invernadero (GEI) se enfrenta al desafío de que muchas empresas aún no reportan sus emisiones de manera continua. Para abordar esta problemática, Assael et al. (2022) proponen un modelo basado en aprendizaje automático que permite estimar las emisiones de Scope 1 (emisiones directas) y Scope 2 (emisiones indirectas por consumo de energía) en aquellas empresas que no las han reportado. Este modelo utiliza datos como el consumo energético, la estructura de activos y la clasificación industrial para generar estimaciones precisas y comparables.

Una de las características más destacadas del modelo es su enfoque en la interpretabilidad mediante el uso de valores de Shapley, lo que permite identificar qué factores específicos contribuyen más a las emisiones de una empresa. Estos valores son una técnica ampliamente utilizada para explicar las predicciones de modelos complejos. Esta técnica, basada en la teoría de juegos, permite atribuir de manera precisa cuánto contribuye cada variable del modelo a la predicción final (Lundberg & Lee, 2017). Basado en el enfoque de los valores de Shapley (Lundberg y Lee, 2017), es posible identificar factores específicos, como el

consumo energético o la intensidad de carbono del país donde opera una empresa, como determinantes clave en el cálculo de emisiones.

Por ejemplo, el consumo energético y la intensidad de carbono del país donde opera la empresa son determinantes clave en el cálculo. Este enfoque no solo mejora la precisión del monitoreo, sino que también facilita la creación de estrategias específicas para reducir las emisiones y cumplir con los objetivos climáticos, como el Net Zero.

4.3. Desafíos en la implementación de técnicas de BD e IA

La transición hacia el objetivo Net Zero, no solo implica superar barreras técnicas y organizacionales, sino que también implica tener en cuenta las complejidades que surgen de la interacción entre la digitalización y la descarbonización. Según Quetglas y Ortega (2021), la digitalización puede desempeñar un papel dual en este proceso, actuando tanto como facilitador de la reducción de emisiones como causante de nuevos desafíos. Por un lado, herramientas tecnológicas como la Inteligencia Artificial y el Big Data, permiten optimizar procesos industriales, mejorar la eficiencia energética y monitorear en tiempo real las emisiones a lo largo de las cadenas de valor. Sin embargo, por otro lado, el desarrollo y la implementación de estas herramientas también generan una huella de carbono significativa, principalmente en el caso de sistemas avanzados de Inteligencia Artificial que necesitan grandes cantidades de energía en el proceso de entrenamiento y producción.

Esta relación destaca la necesidad de equilibrar las ventajas de las tecnologías digitales con el impacto que tienen en el medioambiente. Como señalan Quetglas y Ortega (2021), para que la digitalización sea sostenible tanto a corto como largo plazo, es importante implementar estrategias que minimicen su huella de carbono. Un ejemplo es el uso de energías renovables en los centros de datos y la mejora de la eficiencia en los procesos de procesamiento y almacenamiento de datos. Este balance es fundamental en aquellos sectores intensivos en carbono como el acero, el cemento y el petróleo, donde adquirir y adoptar estas tecnologías puede ser clave para alcanzar los objetivos Net Zero.

Asimismo, la reflexión propuesta por Quetglas y Ortega (2021) amplía el análisis realizado por Rodrigo et al. (2021), haciendo hincapié en la importancia de tener en cuenta

aquellas barreras que puedan surgir como consecuencia de la digitalización de los procesos con el objetivo de lograr una transición sostenible a los objetivos de descarbonización neta.

Esta comparativa de sectores que he realizado hace resaltar que efectivamente, existen diferencias notables en las estrategias necesarias, desafíos y problemas a los que se enfrenta cada industria en específico. Esta diferencia remarca nuevamente la importancia de tener en cuenta cada industria por separado y la necesidad de implementar estrategias de Inteligencia Artificial y Big Data individualizadas y específicas para la reducción de la emisión de gases de las empresas. En este contexto, vuelve a ser fundamental el empleo de estas herramientas innovadoras para optimizar los procesos y contribuir a los objetivos de sostenibilidad en sectores con características variadas.

Aunque la IA y el BD proporcionan muchas ventajas en el ámbito industrial, pueden suponer una resistencia al cambio para las empresas. Esto se debe a que adoptarlas cuesta recursos cuyo acceso a veces puede ser costoso. Según Peñalver-Higuera e Isea-Argüelles (2024), la resistencia al cambio es en parte debido a que no conocen las aplicaciones y las ventajas que pueden proporcionar la IA y el BD. Otra de las razones por las que las empresas se resisten a adoptar estas tecnologías es por el miedo a que reemplacen puestos de trabajo. Asimismo, las empresas industriales no convierten esta inversión en una prioridad ya que esperan obtener incentivos económicos y regulatorios y no se los proporcionan.

Otro de los motivos por los que las empresas no priorizan la inversión en tecnologías de vanguardia es el alto coste que supone implementarlas. Realizar la transición hacia esta nueva forma de trabajar supone la adquisición de software y hardware adaptado a estas tecnologías. Más allá de esto, las empresas tienen que actualizar la infraestructura tecnológica que tienen para poder adoptar los nuevos modelos. Asimismo, es necesario que los trabajadores sean formados y estén capacitados. Esto suma costes económicos adicionales a los mencionados anteriormente, así como costes de adaptación (Peñalver-Higuera & Isea-Argüelles, 2024). Muchas empresas, sobre todo las pymes, ven los costes como una barrera crucial debido a que no tienen los recursos monetarios para permitirse esta transición. Para muchas de ellas, hacer frente a la Industria 4.0 supone comprometer su estabilidad económica.

Finalmente, otra barrera importante es la escasez de personas formadas y capacidades. Cada vez son más las empresas que demandan trabajadores expertos en ciencia de datos, machine learning e inteligencia artificial. Este desafío en la búsqueda de talento supone costes elevados de contratación y hace que la selección de personal sea mucho más compleja (Peñalver-Higuera & Isea-Argüelles, 2024). Esta brecha de conocimientos afecta sobre todo a sectores industriales con estructuras más tradicionales, donde la falta de formación en estas áreas limita la capacidad de las empresas para adoptar y aprovechar el potencial de estas tecnologías. Por lo tanto, si no se abordan estos desafíos, la implementación de BD e IA en industrias clave para la sostenibilidad seguirá siendo un proceso lento y desigual.

5. CONCLUSIÓN

La investigación que presento en este trabajo ha analizado el impacto de la Inteligencia Artificial y el Big Data en la sostenibilidad en los principales sectores industriales, destacando sus aplicaciones, tanto en la reducción de emisiones como en la optimización de procesos en sectores intensivos en carbono como el acero, el cemento, el petróleo, el aluminio, y el papel. Tras haber analizado el estado actual de las empresas respecto a compromisos sostenibles, se ha llevado a cabo un análisis en el que se ha puesto en evidencia que estas tecnologías propias de la Industria 4.0., tienen un papel fundamental en la adopción de procesos más eficientes y avanzados que permitan a las empresas ser más sostenibles.

Uno de los principales hallazgos es que la implementación de IA y BD permite mejorar la eficiencia energética, reducir desperdicios y facilitar el monitoreo en tiempo real de las emisiones industriales, lo que resulta fundamental para alcanzar los objetivos de Net Zero. Sin embargo, también se identificaron desafíos importantes para su adopción, entre las que destacan los altos costos de implementación, la falta de talento especializado y la resistencia al cambio dentro de las organizaciones.

A pesar de estos desafíos, los resultados de este estudio indican que la digitalización y el uso de herramientas avanzadas de análisis de datos representan una oportunidad estratégica para las empresas industriales que buscan mejorar su sostenibilidad. No obstante, para que estas tecnologías sean adoptadas de manera más efectiva, es necesario que las empresas

desarrollen estrategias individualizadas, reciban incentivos financieros y cuenten con políticas gubernamentales claras que fomenten la digitalización sostenible.

En la realización de este trabajo he encontrado una serie de limitaciones entre las que me gustaría destacar las siguientes. Asimismo, considero que otra limitación es la ausencia de un análisis cuantitativo sobre el impacto en ciertos sectores. Es decir, la realización de un análisis comparativo de las cifras de negocio de una empresa anteriores a la implementación de estas tecnologías, con las cifras tras haber implementado los nuevos procesos. Por ello, una línea de investigación futura interesante sería analizar casos concretos que investiguen la implementación real de IA y BD en fábricas específicas y su impacto directo en la reducción de emisiones.

En conclusión, la IA y el Big Data tienen el potencial de transformar la industria hacia modelos más sostenibles, pero su adopción efectiva dependerá de la superación de desafíos tecnológicos, económicos y organizacionales propios de cada sector. La transición hacia una industria más eficiente y ecológica requiere no solo de avances tecnológicos, sino también de un compromiso estratégico y regulatorio que impulse el cambio de manera estructural.

6. DECLARACIÓN DE USO DE INTELIGENCIA ARTIFICIAL

Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado

ADVERTENCIA: Desde la Universidad consideramos que ChatGPT u otras herramientas similares son herramientas muy útiles en la vida académica, aunque su uso queda siempre bajo la responsabilidad del alumno, puesto que las respuestas que proporciona pueden no ser veraces. En este sentido, NO está permitido su uso en la elaboración del Trabajo fin de Grado para generar código porque estas herramientas no son fiables en esa tarea. Aunque el código funcione, no hay garantías de que metodológicamente sea correcto, y es altamente probable que no lo sea.

Por la presente, yo, Valeria Cagigas Gabriel, estudiante de E2 Analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado " El Impacto De La Inteligencia Artificial Y El Big Data En La Sostenibilidad Industrial: Aplicaciones Y Desafíos En Sectores Clave", declaro que he utilizado la herramienta de Inteligencia

Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación [el alumno debe mantener solo aquellas en las que se ha usado ChatGPT o similares y borrar el resto. Si no se ha usado ninguna, borrar todas y escribir “no he usado ninguna”]:

1. Referencias: Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.

2. Metodólogo: Para descubrir métodos aplicables a problemas específicos de investigación.

3. Constructor de plantillas: Para diseñar formatos específicos para secciones del trabajo.

4. Corrector de estilo literario y de lenguaje: Para mejorar la calidad lingüística y estilística del texto.

5. Sintetizador y divulgador de libros complicados: Para resumir y comprender literatura compleja.

6. Generador de problemas de ejemplo: Para ilustrar conceptos y técnicas.

7. Traductor: Para traducir textos de un lenguaje a otro.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 24 de marzo de 2025

Firma: Valeria Cagigas Gabriel

7. BIBLIOGRAFÍA

- Acerinox. (2023). Informe de Gobierno Corporativo 2022. <https://www.acerinox.com/en/accionistas-e-inversores/informacion-economica-financiera/presentaciones/2022-Annual-Corporate-Governance-Report>
- U.S. Environmental Protection Agency. (2025, February 22). *Understanding global warming potentials*. <https://www.epa.gov/ghgemissions/understanding-global-warming-potentials>
- Air Liquide. (2023). Sustainability Report 2023. https://usa.airliquide.com/sites/al_us/files/2024-04/airliquide-sustainability-report-2023.pdf
- Annual report 2023*. (s. f.). Hydro. <https://www.hydro.com/en/global/investors/reports-and-presentations/annual-reports/annual-report-2023/>
- ArcelorMittal. (2023). Informe Anual Integrado 2022. <https://corporate.arcelormittal.com/media/tmabqjue/arcelor-mittal-integrated-annual-review-2022.pdf>
- Assael, J., Heurtebize, T., Carlier, L., & Soupé, F. (2023). Greenhouse gases emissions: estimating corporate non-reported emissions using interpretable machine learning. *Sustainability*, 15(4), 3391. <https://doi.org/10.3390/su15043391>
- Bahaloo, S., Mehrizadeh, M., & Najafi-Marghmaleki, A. (2023). Review of application of artificial intelligence techniques in petroleum operations. *Petroleum Research*, 8(167-182). <https://doi.org/10.1016/j.ptlrs.2022.07.002>
- Barbhuiya, S., Kanavaris, F., Das, B. B., & Idrees, M. (2024). Decarbonising cement and concrete production: Strategies, challenges and pathways for sustainable development. *Journal of Building Engineering*, 86, 108861. <https://doi.org/10.1016/j.jobe.2024.108861>
- BASF SE. (2023). BASF Report 2022. <https://report.basf.com/2022/en>

- Benito, G. R. G., & Meyer, K. E. (2024). Industrial policy, green challenges, and international business. *Journal of International Business Studies*, 55(5), 1093–1107. <https://doi.org/10.1057/s41267-024-00722-6>
- Boukhari, Y. (2020). Using intelligent models to predict weight loss of raw materials during cement clinker production. *Revue d'Intelligence Artificielle*, 34(1), 101-110. <https://doi.org/10.18280/ria.340114>
- Cátedra BP de Medio Ambiente. (2024, febrero 13). *El uso de la IA y los datos podría romper el vínculo entre crecimiento económico y emisiones de carbono*. Universidad Politécnica de Madrid. <https://www.catedrabpmedioambiente.es/el-uso-de-la-ia-y-los-datos-podria-romper-el-vinculo-entre-crecimiento-economico-y-emisiones-de-carbono/>
- BP. (2023). Informe de Sostenibilidad 2022. <https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/sustainability/group-reports/bp-sustainability-report-2022.pdf>
- Buzzi SpA. (2023). Sustainability Report 2022. <https://sustainability.buzzi.com/wp-content/uploads/2023/10/Sustainability-Report-2022.pdf>
- Chrysikopoulos, S. K., Chountalas, P. T., Georgakellos, D. A., & Lagodimos, A. G. (2024). Decarbonization in the oil and gas sector: The role of power purchase agreements and renewable energy certificates. *Sustainability*, 16(6339). <https://doi.org/10.3390/su16156339>
- Constellium. (2023). Informe de Sostenibilidad 2022. <https://www.constellium.com/news/constellium-releases-its-2022-sustainability-report>
- CRH. (2023). Informe de Desempeño de Sostenibilidad 2022. <https://www.crh.com/media/4748/crh-2022-sustainability-performance-report-interactive.pdf>
- Del Rio, D. D. F., Sovacool, B. K., Griffiths, S., Bazilian, M., Kim, J., Foley, A. M., & Rooney, D. (2022). Decarbonizing the pulp and paper industry: A critical and

- systematic review of sociotechnical developments and policy options. *Renewable And Sustainable Energy Reviews*, 167, 112706. <https://doi.org/10.1016/j.rser.2022.112706>
- DS Smith plc. (2023). Informe de Sostenibilidad 2024. <https://www.dssmith.com/es/sostenibilidad/informes-rendimiento-y-datos/informe-de-sostenibilidad>
- Elkington, J. (1997). Cannibals with forks: the triple bottom line of 21st century business. *Choice Reviews Online*, 36(07), 36-3997. <https://doi.org/10.5860/choice.36-3997>
- Equinor ASA. (2023). *Informe Anual 2022*. <https://www.equinor.com/investors/2022-annual-report>
- Evonik Industries AG. (2023). *Sustainability Report 2022*. <https://files.evonik.com/shared-files/sustainability-report-2022-8618.pdf>
- Federal Office for Spatial Development ARE. (s.f.). *1987: Brundtland Report*. Admin.ch. <https://www.are.admin.ch/are/en/home/media/publications/sustainable-development/brundtland-report.html>
- Gangwar, A., Singh, S., Mishra, R., & Prakash, S. (2023). The state-of-the-art in air pollution monitoring and forecasting systems using IoT, big data, and machine learning. *Wireless Personal Communications*, 130(3), 1699-1729. <https://doi.org/10.1007/s11277-023-10351-1>
- Griffiths, S., Sovacool, B. K., Furszyfer Del Rio, D. D., Foley, A. M., Bazilian, M. D., Kim, J., & Uratani, J. M. (2023). Decarbonizing the cement and concrete industry: A systematic review of socio-technical systems, technological innovations, and policy options. *Renewable and Sustainable Energy Reviews*, 180(113291), 113291. <https://doi.org/10.1016/j.rser.2023.113291>
- Gupta, M., & George, J. F. (2016). Toward the development of a big data analytics capability. *Information & Management*, 53(8), 1049-1064. <https://doi.org/10.1016/j.im.2016.07.004>

- Hämäläinen, E., & Inkinen, T. (2019). Big data in emission producing manufacturing industries – An explorative literature review. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV-4/W9, 57–64. <https://doi.org/10.5194/isprs-annals-IV-4-W9-57-2019>
- Heidelberg Materials. (2023). Informe Anual y de Sostenibilidad 2022. <https://www.heidelbergmaterials.com/en/company/annual-reports-sustainability-reports>
- Holcim. (2023). Informe de Desempeño de Sostenibilidad 2022. <https://www.holcim.com/sites/holcim/files/2023-02/24022023-sustainability-holcim-fy-2022-report-en-3114693266.pdf>
- Iftikhar, B., Alih, S. C., Vafaei, M., Elkotb, M. A., Shutaywi, M., Javed, M. F., Deebani, W., Khan, M. I., & Aslam, F. (2022). Predictive modeling of compressive strength of sustainable rice husk ash concrete: Ensemble learner optimization and comparison. *Journal Of Cleaner Production*, 348, 131285. <https://doi.org/10.1016/j.jclepro.2022.131285>
- Instituto Nacional de Estadística. (2021). Empresas con 10 o más empleados: Las TIC en las empresas (primer trimestre de 2021). <https://ine.es/jaxi/Tabla.htm?L=0&tpx=49864>
- Integral Innovation Experts. (2023). La sostenibilidad en el sector industrial: un camino hacia el futuro. *Integral Innovation Experts Blog*. <https://integralplm.com/blog/2023/02/27/la-sostenibilidad-en-el-sector-industrial-un-camino-hacia-el-futuro/>
- Jauhar, S. K., Raj, P. V. R. P., Kamble, S., Pratap, S., Gupta, S., & Belhadi, A. (2024). A deep learning-based approach for performance assessment and prediction: A case study of pulp and paper industries. *Annals of Operations Research*, 1-27. <https://doi.org/10.1007/s10479-022-04528-3>
- Kim, S. W., Kong, J. H., Lee, S. W., & Lee, S. (2022). Recent advances of artificial intelligence in manufacturing industrial sectors: A review. *International Journal of Precision Engineering and Manufacturing*, 1-19. <https://doi.org/10.1007/s12541-021-00600-3>

- Liao, M., Lan, K., & Yao, Y. (2022). Sustainability implications of artificial intelligence in the chemical industry: A conceptual framework. *Journal of Industrial Ecology*, 26(1), 164–182. <https://doi.org/10.1111/jiec.13214>
- Liu, J., Liu, G., Zhao, H., Zhao, J., Qiu, J., & Dong, Z. Y. (2024). Real-time industrial carbon emission estimation with deep learning-based device recognition and incomplete smart meter data. *Engineering Applications of Artificial Intelligence*, 127, 107272. <https://doi.org/10.1016/j.engappai.2023.107272>
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765–4774. <https://proceedings.neurips.cc/paper/2017/file/8a20a8621978632d76c43dfd28b67767-Paper.pdf>
- Martín Ortega, E. (2021). Digitalización y descarbonización: una relación compleja. *Real Instituto Elcano*. <https://media.realinstitutoelcano.org/wp-content/uploads/2021/04/dt7-20201-martin-ortega-digitalizacion-con-descarbonizacion.pdf>
- Masnadi, M. S., El-Houjeiri, H. M., Schunack, D., Li, Y., Englander, J. G., Badahdah, A., Monfort, J., Anderson, J. E., Wallington, T. J., Bergerson, J. A., Gordon, D., Koomey, J., Przesmitzki, S., Azevedo, I. L., Bi, X. T., Duffy, J. E., Heath, G. A., Keoleian, G. A., McGlade, C., . . . Brandt, A. R. (2018). Global carbon intensity of crude oil production. *Science*, 361(6405), 851-853. <https://doi.org/10.1126/science.aar6859>
- McKim, A. S. (2018). Overcoming sustainability barriers within the chemical industry. *Current Opinion In Green And Sustainable Chemistry*, 14, 10-13. <https://doi.org/10.1016/j.cogsc.2018.04.020>
- Meyer, N. (2018). Decarbonizing U.S. oil and gas: Climate innovation. Center for Climate and Energy Solutions <https://www.c2es.org/document/innovation-oil-gas-background-brief-07-18/>.
- Ministerio para la Transición Ecológica y el Reto Demográfico. (2022). Fabricación de aluminio (emisiones de proceso). Sistema Español de Inventario de Emisiones <https://www.miteco.gob.es/content/dam/miteco/es/calidad-y-evaluacion->

[ambiental/temas/sistema-espanol-de-inventario-sei-/040301-fabric-aluminio_tcm30-502319.pdf](#)

MYTILINEOS ANNUAL REPORT 2023.

(s. f.). <https://www.metlengroup.com/interactive-document/annual-report-2023-eng/index.html>

Padamata, S. K., Yasinskiy, A., & Polyakov, P. (2021). A review of secondary aluminum production and its byproducts. *JOM*, 73(8), 2603–2614. <https://doi.org/10.1007/s11837-021-04802-y>

Peñalver-Higuera, M. J., & Isea-Argüelles, J. J. (2024). Transformación hacia fábricas inteligentes: El papel de la IA en la industria 4.0. *Ingenium et Potentia. Revista Electrónica Multidisciplinaria de Ciencias Básicas, Ingeniería y Arquitectura*, 6(10), 38-53. <https://doi.org/10.35381/i.p.v6i10.3742>

PwC, Microsoft, & Instituto de Cambio Medioambiental de la Universidad de Oxford. (2024). Informe sobre la aplicación de la inteligencia artificial en la reducción de emisiones de carbono. <https://www.pwc.es/es/consultoria/informe-la-clave-longevidad-empresas-ia.html>

Quetglas, G., & Ortega, A. (2021). *Digitalización con descarbonización* (Documento de trabajo N° 7/2021). Real Instituto Elcano <https://media.realinstitutoelcano.org/wp-content/uploads/2021/04/dt7-20201-martin-ortega-digitalizacion-con-descarbonizacion.pdf>

Repsol. (2023). Informe de Gestión Integrado 2022. https://www.repsol.com/content/dam/repsol-corporate/en_gb/accionistas-e-inversores/resultados/2022/q4/integrated-management-report-2022.pdf

Rio Tinto. (2023). Informe de sostenibilidad 2022. <https://www.riotinto.com/-/media/content/documents/invest/reports/annual-reports/2022/rt-annual-report-2022.pdf>

Roa, B. (2024). Sector Industrial: la sostenibilidad, principal impulsor del cambio en los modelos de negocio. *BBVA CIB*. <https://www.bbvacib.com/es/insights/news/sector->

[industrial-la-sostenibilidad-principal-impulsor-del-cambio-en-los-modelos-de-negocio/](#)

- Rodrigo, P. H., Richard, W. H., & Enrique, L. D. (2021). Uso, obstáculos y desafíos para el desarrollo del big data e inteligencia artificial en la industria energética en Chile. <https://repositorio.uchile.cl/handle/2250/181841>
- Sadighi, S., Mohaddecy, R. S., & Ameri, Y. A. (2015). Artificial neural network modeling and optimization of Hall-Heroult process for aluminum production. *International Journal of Technology*, 6(3), 444–453. <https://ijtech.eng.ui.ac.id/article/view/1369>
- Saevarsdottir, G., Kvande, H., & Welch, B. J. (2019). Aluminum production in the Times of Climate Change: The global challenge to reduce the carbon footprint and prevent carbon leakage. *JOM*, 72(1), 296–308. <https://doi.org/10.1007/s11837-019-03918-6>
- Sellitto, M. A. (2018). Reverse logistics activities in three companies of the process industry. *Journal Of Cleaner Production*, 187, 923-931. <https://doi.org/10.1016/j.jclepro.2018.03.262>
- Shell plc. (2023). *Sustainability Report 2022*. <https://reports.shell.com/sustainability-report/2022>
- Smurfit Kappa. (2023). Informe de Desarrollo Sostenible 2023. <https://www.smurfitkappa.com/es/sustainability/reporting>
- Solvay SA. (2023). 2022 Annual Integrated Report. <https://www.solvay.com/en/2022-annual-integrated-report>
- Souza Filho, I. R., Ma, Y., Kulse, M., Ponge, D., Gault, B., Springer, H., & Raabe, D. (2022). Sustainable steel through hydrogen plasma reduction of iron ore: Process, kinetics, microstructure, chemistry. *arXiv preprint arXiv:2208.00661*. <https://arxiv.org/abs/2208.00661>
- Souza Filho, I. R., Springer, H., Ma, Y., Mahajan, A., da Silva, C. C., Kulse, M., & Raabe, D. (2022). *Green steel at its crossroads: Hybrid hydrogen-based reduction of iron ores*. Max-Planck-Institut für Eisenforschung. <https://arxiv.org/pdf/2201.13356.pdf>

- SSAB. (2023). *Informe Anual 2022*. https://www.ssab.com/-/media/Files/Company/Investors/Annual-reports/2022/SSAB_Annual_Report_2022.pdf
- Stora Enso. (2023). *Annual Report 2022*. https://www.storaenso.com/-/media/documents/download-center/documents/annual-reports/2022/storaenso_annual_report_2022.pdf
- Teske, S., Nagrath, K., Niklas, S., Talwar, S., Atherton, A., Orbe, J. G., Assaf, J., & Giurco, D. (2022). Scopes 1, 2, and 3 Industry Emissions and Future Pathways. En *Springer eBooks* (pp. 315-336). https://doi.org/10.1007/978-3-030-99177-7_13
- ThyssenKrupp AG. (2023). *Informe Anual 2021/2022*. <https://ucpcdn.thyssenkrupp.com/binary/UCPthyssenkruppAG/en/investors/reporting-and-publications/thyssenkrupp-annual-report-2021-2022.pdf>
- TotalEnergies. (2023). *Sustainability & Climate 2022 Progress Report*. https://totalenergies.com/sites/g/files/nytnzq121/files/documents/2022-05/Sustainability_Climate_2022_Progress_Report_accessible_version_EN.pdf
- UC RUSAL. (2023). *Informe de Sostenibilidad 2022*. <https://rusal.ru/en/sustainability/report/>
- UPM-Kymmene. (2023). *Informe de Sostenibilidad 2022*. https://www.upm.com/siteassets/documents/responsibility/1-fundamentals/emas-reports/global-reports/upm_corp_emas_2022_es.pdf
- Vinuesa, R., Azizpour, H., Leite, I., Balaam, M., Dignum, V., Domisch, S., Felländer, A., Langhans, S. D., Tegmark, M., & Fusco Nerini, F. (2020). The role of artificial intelligence in achieving the Sustainable Development Goals. *Nature Communications, 11*, Article 233. <https://doi.org/10.1038/s41467-019-14108-y>
- Voestalpine AG. (2023). *Informe de Responsabilidad Corporativa 2022/23*. <https://reports.voestalpine.com/2023/cr-report>
- Zhou, K., Fu, C., & Yang, S. (2016). Big data driven smart energy management: From big data to big insights. *Renewable And Sustainable Energy Reviews, 56*, 215-225. <https://doi.org/10.1016/j.rser.2015.11.050>

8. ANEXOS

8.1. Anexo I. Código empleado para la realización de las Ilustraciones y análisis de bases de datos

24/3/25, 22:12

Código TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

TFG ADE VALERIA CAGIGAS GABRIEL. E2

ANALYTICS

Código Visualizaciones COMPARACIÓN SECTORES

1. Industria Aluminio

In [2]:

```
import pandas as pd
import matplotlib.pyplot as plt
# cargo las bases de datos
data_alum = pd.ExcelFile("Aluminium database.xlsx")
df_alum = data_alum.parse("Hoja1", header=0) # La primera fila será el encabezad
# doy nombre a columnas para luego poder hacer referencia a ellas de forma más fá
df_alum.columns = [
"Company", "Objectives", "Other_Details", "Target_Year", "Target_Status",
"Transition_Plan", "Transition_Plan_Timing", "CAPEX_Plans", "Gases_Covered",
"Scope_1_Target", "Scope_2_Target", "Scope_3_Target", "Scope_3_Planning",
"Carbon_Credits", "Offset_Percentage", "Offset_Details", "UN_Membership",
"Methodology", "Additional_Info"
]
df_alum = df_alum.dropna(subset=["Company"]) #elimino filas en las que no hay nomb
# Quito la columna que me interesa de los años net zero
net_zero_years_alum = df_alum["Target_Year"].str.extract(r"(\d{4})", expand=False)
# Contar empresas con planes de transición
transition_plans_alum = df_alum["Transition_Plan_Timing"].dropna()
medium_term_alum = transition_plans_alum.str.contains("medium term", case=False).
long_term_alum = transition_plans_alum.str.contains("long term", case=False).sum()
# Análisis de cobertura de alcances
scopes_alum = {
"Scope 1": df_alum["Scope_1_Target"].str.contains("Yes", case=False, na=False)
"Scope 2": df_alum["Scope_2_Target"].str.contains("Yes", case=False, na=False)
"Scope 3": df_alum["Scope_3_Target"].str.contains("Yes", case=False, na=False)
}
# Análisis de cobertura de gases
gases_covered_alum = df_alum["Gases_Covered"].str.contains("Yes", case=False, na=
gases_not_covered_alum = len(df_alum) - gases_covered_alum
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
1/35
```

24/3/25, 22:12

Código TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [3]:

Años de metas net-zero

plt.figure(figsize=(4, 4))

```

plt.hist(net_zero_years_alum, color="lightgreen", bins=20)
plt.title("Años Objetivo Net Zero. Industria Aluminio.")
plt.xlabel("Año")
plt.ylabel("Número Empresas")
plt.grid(axis="y", linestyle="-", alpha=0.2)
max_y = int(plt.gca().get_ylim()[1]) # Obtener el límite superior del eje Y
plt.yticks(range(0, max_y + 1))
plt.xticks(range(net_zero_years_alum.min(), net_zero_years_alum.max() + 5, 5))
plt.show()

```

localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
2/35

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [4]:

In [6]:

Planes de transición (medio vs largo plazo)

```

plt.figure(figsize=(7, 2))
plt.bar(["Medio Plazo", "Largo Plazo"], [medium_term_alum, long_term_alum], color
plt.title("Número de Empresas con Planes de Transición. Industria Aluminio.")
plt.yticks(range(0, max(medium_term_alum, long_term_alum) + 1, 1)) #Esto lo he he
#que se vean todas las que tienen los objetivos. Como son pocas puede ir de 1 en 1
plt.ylabel("Número Empresas")
plt.show()

```

Cobertura de alcances

```

plt.figure(figsize=(7, 2))
plt.bar(scopes_alum.keys(), scopes_alum.values(), color="lightcoral")
plt.title("Scope 1, 2 y 3 por Empresas. Industria Aluminio.")
plt.yticks(range(0, max(scopes_alum.values()) + 1, 1))
plt.ylabel("Número Empresas")
plt.show()

```

localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
3/35

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [20]:

```

lista_gases_alum = df_alum["Gases_Covered"].dropna().str.split("\n").explode()
# con esto cuento la frecuencia de los gases, es decir las veces que aparece x ga
contador_gases_alum = lista_gases_alum.value_counts()
gases_por_compañia_alum = df_alum["Gases_Covered"].dropna().str.split("\n").explor
# Como me salen muchísimos gases (todos los de todas las compañías), lo que hago
# a todas las empresas de la industria del aluminio
gases_todas_compañias_alum = gases_por_compañia_alum[gases_por_compañia_alum
== 1
# Mostrar los gases más frecuentes (top 10)
gases_fundamentales_alum = gases_por_compañia_alum.head(10) # Mostrar los 10 gas
print("Gases más frecuentes en la industria del aluminio:")
print(gases_fundamentales_alum)

```

```

# Generar el gráfico de barras para los gases más cubiertos
plt.figure(figsize=(7, 2))
gases_fundamentales_alum.plot(kind="bar", color="lightcoral", edgecolor="black")
plt.title("Gases Más Relevantes en la Industria del Aluminio")
plt.xlabel("Gases")
plt.ylabel("Frecuencia")
plt.xticks(rotation=45, ha="right", fontsize=8) # Reducir el tamaño de la fuente
plt.grid(axis="y", linestyle="--", alpha=0.7)
plt.show()
Gases más frecuentes en la industria del aluminio:
CO2 (Carbon Dioxide)      5
CH4 (Methane)           5
N2O (Nitrous Oxide)     5
PFCs (Perfluorocarbons)   4
HFCs (Hydrofluorocarbons) 3
SF6 (Sulfur Hexafluoride) 3
NF3 (Nitrogen Trifluoride) 2
Name: Gases_Covered, dtype: int64
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
4/35
24/3/25, 22:12
Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook
2. Industria Química
In [21]:
In [8]:
import pandas as pd
import matplotlib.pyplot as plt
data_chem = pd.ExcelFile("Chemicals database.xlsx")
df_chem = data_chem.parse("Hoja1", header=0)
df_chem.columns = [
"Company", "Objectives", "Other_Details", "Target_Year", "Target_Status",
"Transition_Plan", "Transition_Plan_Timing", "CAPEX_Plans", "Gases_Covered",
"Scope_1_Target", "Scope_2_Target", "Scope_3_Target", "Scope_3_Planning",
"Carbon_Credits", "Offset_Percentage", "Offset_Details", "UN_Membership", "Met
]
df_chem = df_chem.dropna(subset=["Company"])
net_zero_years_chem = df_chem["Target_Status"].str.extract(r"(\d{4})", expand=False)
transition_plans_chem = df_chem["Transition_Plan_Timing"].dropna()
medium_term_chem = transition_plans_chem.str.contains("medium term", case=False).
long_term_chem = transition_plans_chem.str.contains("long term", case=False).sum(
scopes_chem = {
"Scope 1": df_chem["Scope_1_Target"].str.contains("Yes", case=False, na=False)
"Scope 2": df_chem["Scope_2_Target"].str.contains("Yes", case=False, na=False)
"Scope 3": df_chem["Scope_3_Target"].str.contains("Yes", case=False, na=False)
}
gases_covered_chem = df_chem["Gases_Covered"].str.contains("Yes", case=False, na=
gases_not_covered_chem = len(df_chem) - gases_covered_chem

```

```
#Compruebo los años de la columna que tengo de status net zero de las empresas pa  
net_zero_years_chem
```

```
Out[8]: 0 2050
```

```
1 2050
```

```
2 2030
```

```
3 2030
```

```
4 2030
```

```
5 2030
```

```
6 2035
```

```
Name: Target_Status, dtype: int32
```

```
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb  
5/35
```

```
24/3/25, 22:12
```

```
Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook
```

```
In [22]:
```

```
plt.figure(figsize=(4,4))
```

```
plt.hist(net_zero_years_chem, color="lightgreen", bins=20)
```

```
plt.title("Años Objetivo Net Zero. Industria Química.")
```

```
plt.xlabel("Año")
```

```
plt.ylabel("Número de Empresas")
```

```
plt.grid(axis="y", alpha=0.2)
```

```
max_y = int(plt.gca().get_ylim()[1]) # Obtener el límite superior del eje Y
```

```
plt.yticks(range(0, max_y + 1))
```

```
plt.xticks(range(net_zero_years_chem.min(), net_zero_years_chem.max() + 5, 5)) #E
```

```
#de net zero y el máximo y luego ponga 5 de margen y que vaya de 5 en 5.
```

```
plt.show()
```

```
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb  
6/35
```

```
24/3/25, 22:12
```

```
Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook
```

```
In [23]:
```

```
In [24]:
```

```
# Planes de transición (medio vs largo plazo)
```

```
plt.figure(figsize=(7, 2))
```

```
plt.bar(["Medio Plazo", "Largo Plazo"], [medium_term_chem, long_term_chem], color
```

```
plt.yticks(range(0, max(medium_term_chem, long_term_chem) + 1, 1)) #Esto lo he he
```

```
#que se vean todas las que tienen los objetivos. Como son pocas puede ir de 1 en 1
```

```
plt.title("Número de Empresas con Planes de Transición. Industria Química.")
```

```
plt.ylabel("Número Empresas")
```

```
plt.show()
```

```
# Cobertura de alcances
```

```
plt.figure(figsize=(7, 2))
```

```
plt.bar(scopes_chem.keys(), scopes_chem.values(), color="lightcoral")
```

```
plt.title("Scope 1, 2 y 3 por Empresas. Industria Química.")
```

```
plt.yticks(range(0, max(scopes_chem.values()) + 1, 1))
```

```
plt.ylabel("Número Empresas")
```

```
plt.show()
```

localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
7/35

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [27]:

```
#Lo primero que tengo que hacer es convertir los gases de todas las comp a listas
#mas organizado
lista_gases_chem = df_chem["Gases_Covered"].dropna().str.split("\n").explode()
# Contar la frecuencia de cada gas
contador_gases_chem = lista_gases_chem.value_counts()
gases_por_compañia_chem = df_chem["Gases_Covered"].dropna().str.split("\n").explo
#Como me salen muchisimos gases (todos los de todas las compañías), lo que hago e
#a las 7 empresas de la industria química
gases_todas_compañias_chem = gases_por_compañia_chem[gases_por_compañia_chem
== 1
gases_todas_compañias_chem
gases_fundamentales_chem = gases_por_compañia_chem.head(10) # Mostrar los 10 gas
gases_fundamentales_chem
plt.figure(figsize=(4, 4))
gases_fundamentales_chem.plot(kind="bar", color="lightcoral", edgecolor="black")
plt.title("Gases Más Relevantes en la Industria Química")
plt.xlabel("Gases")
plt.ylabel("Frecuencia")
plt.xticks(rotation=45, ha="right", fontsize=8)
plt.grid(axis="y", linestyle="--", alpha=0.7)
plt.show()
```

localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
8/35

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

3. Industria Cemento

In [28]:

In [29]:

```
import pandas as pd
import matplotlib.pyplot as plt
data_concrete = pd.ExcelFile("Concrete database.xlsx")
df_concrete= data_concrete.parse("Hoja1", header=0)
df_concrete.columns = [
"Company", "Objectives", "Other_Details", "Target_Year", "Net_Zero_Plan", "Tar
"Transition_Plan", "Transition_Plan_Timing", "CAPEX_Plans", "Gases_Covered",
"Scope_1_Target", "Scope_2_Target", "Scope_3_Target", "Scope_3_Planning",
"Carbon_Credits", "Offset_Percentage", "Offset_Details", "UN_Membership",
"Methodology"
]
df_concrete = df_concrete.dropna(subset=["Company"])
net_zero_years_concrete = df_concrete["Target_Status"].str.extract(r"(\d{4})", ex
transition_plans_concrete = df_concrete["Transition_Plan_Timing"].dropna()
```

```

medium_term_concrete = transition_plans_concrete.str.contains("medium term", case
long_term_concrete = transition_plans_concrete.str.contains("long term", case=Fa
scopes_concrete = {
"Scope 1": df_concrete["Scope_1_Target"].str.contains("Yes", case=False, na=F
"Scope 2": df_concrete["Scope_2_Target"].str.contains("Yes", case=False, na=F
"Scope 3": df_concrete["Scope_3_Target"].str.contains("Yes", case=False, na=F
}
gases_covered_concrete = df_concrete["Gases_Covered"].str.contains("Yes", case=Fa
gases_not_covered_concrete = len(df_concrete) - gases_covered_concrete
net_zero_years_concrete

```

```

Out[29]: 0    2030
1    2030
2    2050
3    2050

```

Name: Target_Status, dtype: int32

localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
9/35

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

```

In [30]:
plt.figure(figsize=(4, 4))
plt.hist(net_zero_years_concrete, color="lightgreen", bins=10, rwidth=1.0)
plt.title("Años Objetivo Net Zero. Industria Cemento.")
plt.xlabel("Año")
plt.ylabel("Número de Empresas")
plt.grid(axis="y", alpha=0.2)
max_y = int(plt.gca().get_ylim()[1]) # para tener el limite superior del eje y
plt.yticks(range(0, max_y + 1))
plt.xticks(sorted(net_zero_years_concrete.unique())) #Esto basicamente que me coj
#empresas
plt.show()

```

localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
10/35

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

```

In [31]:
# Planes de transición (medio vs largo plazo)
plt.figure(figsize=(7, 2))
plt.bar(["Medio Plazo", "Largo Plazo"], [medium_term_concrete, long_term_concrete
plt.yticks(range(0, max(medium_term_concrete, long_term_concrete) + 1, 1)) #Esto
#que se vean todas las que tienen los objetivos. Como son pocas puede ir de 1 en 1
plt.title("Número de Empresas con Planes de Transición. Industria Química.")
plt.ylabel("Número Empresas")
plt.show()

```

localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
11/35

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [32]:

```
#Lo primero que tengo que hacer es convertir los gases de todas las comp a listas
#mas organizado
lista_gases_concrete = df_concrete["Gases_Covered"].dropna().str.split("\n").expl
# Contar la frecuencia de cada gas
contador_gases_concrete = lista_gases_concrete.value_counts()
gases_por_compañia_concrete = df_concrete["Gases_Covered"].dropna().str.split("\n
#Como me salen muchisimos gases (todos los de todas las compañías), lo que hago e
#a las 7 empresas de la industria química
gases_todas_compañias_concrete = gases_por_compañia_concrete[gases_por_compañia_c
gases_todas_compañias_concrete
gases_fundamentales_concrete = gases_por_compañia_concrete.head(10) # Mostrar lo
gases_fundamentales_concrete
# Generar el gráfico de barras para los gases más cubiertos
plt.figure(figsize=(7, 2))
gases_fundamentales_concrete.plot(kind="bar", color="lightcoral", edgecolor="blac
plt.title("Gases Más Relevantes en la Industria Cemento")
plt.xlabel("Gases")
plt.ylabel("Frecuencia")
plt.xticks(rotation=45, ha="right")
plt.grid(axis="y", linestyle="--", alpha=0.7)
plt.show()
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
12/35
```

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

4. Idustria Petrolera

In [34]:

In [35]:

```
import pandas as pd
import matplotlib.pyplot as plt
data_oil = pd.ExcelFile("Oil database.xlsx")
df_oil = data_oil.parse("Hoja1", header=0)
df_oil.columns = [
"Company", "Objectives", "Other_Details", "Target_Year", "Target_Status", "Net_
"Transition_Plan", "Transition_Plan_Timing", "CAPEX_Plans", "Gases_Covered",
"Scope_1_Target", "Scope_2_Target", "Scope_3_Target", "Scope_3_Planning",
"Carbon_Credits", "Offset_Percentage", "Offset_Details", "UN_Membership",
"Methodology"
]
df_oil = df_oil.dropna(subset=["Company"])
net_zero_years_oil = df_oil["Target_Status"].str.extract(r"(\d{4})", expand=False)
transition_plans_oil = df_oil["Transition_Plan_Timing"].dropna()
medium_term_oil = transition_plans_oil.str.contains("medium term", case=False).su
long_term_oil = transition_plans_oil.str.contains("long term", case=False).sum()
scopes_oil = {
```

```
"Scope 1": df_oil["Scope_1_Target"].str.contains("Yes", case=False, na=False)
"Scope 2": df_oil["Scope_2_Target"].str.contains("Yes", case=False, na=False)
"Scope 3": df_oil["Scope_3_Target"].str.contains("Yes", case=False, na=False)
}
gases_covered_oil = df_oil["Gases_Covered"].str.contains("Yes", case=False, na=Fa
gases_not_covered_oil = len(df_oil) - gases_covered_oil
net_zero_years_oil
Out[35]: 0  2050
1  2050
2  2050
3  2050
4  2050
Name: Target_Status, dtype: int32
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
13/35
```

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [36]:

```
plt.figure(figsize=(4, 4)) #esto lo he puesto para que el gráfico mida lo mismo d
#una columna y quedaba raro tan alargado.
plt.hist(net_zero_years_oil, color="lightgreen", bins=5, rwidth=0.9)
plt.title("Años Objetivo Net Zero. Industria Petrolera.")
plt.xlabel("Año")
plt.ylabel("Número de Empresas")
plt.xticks([2050])
plt.grid(axis="y", alpha=0.2)
plt.yticks(range(0, 6, 1)) # Esto lo he hecho para que me vaya el eje y de 1 en
#hasta 6 para asegurarme de que me coge todas.
plt.show()
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
14/35
```

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [37]:

```
# Planes de transición (medio vs largo plazo)
```

```
plt.figure(figsize=(7, 2))
plt.bar(["Medio Plazo", "Largo Plazo"], [medium_term_oil, long_term_oil], color=[
plt.yticks(range(0, max(medium_term_oil, long_term_oil) + 1, 1)) #Esto lo he hech
#que se vean todas las que tienen los objetivos. Como son pocas puede ir de 1 en 1
plt.title("Número de Empresas con Planes de Transición. Industria Petrolera.")
plt.ylabel("Número Empresas")
plt.show()
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
15/35
```

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [38]:

```

lista_gases_oil = df_oil["Gases_Covered"].dropna().str.split("\n").explode().str.
# Filtrar gases no vacíos
lista_gases_oil = lista_gases_oil[lista_gases_oil != ""] ### Eliminar entradas v
contador_gases_oil = lista_gases_oil.value_counts()
gases_fundamentales_oil = contador_gases_oil.head(10)
plt.figure(figsize=(7, 2))
gases_fundamentales_oil.plot(kind="bar", color="lightcoral", edgecolor="black")
plt.title("Gases Más Relevantes en la Industria Petrolera")
plt.xlabel("Gases")
plt.ylabel("Frecuencia")
plt.xticks(rotation=45, ha="right")
plt.grid(axis="y", linestyle="--", alpha=0.7)
plt.show()
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
16/35

```

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

5. Idustria Papel

In [39]:

```

import pandas as pd
import matplotlib.pyplot as plt
data_paper = pd.ExcelFile("Paper database.xlsx")
df_paper = data_paper.parse("Hoja1", header=0)
df_paper.columns = [
"Company", "Objectives", "Other_Details", "Target_Year", "Target_Status", "Net_
"Transition_Plan", "Transition_Plan_Timing", "CAPEX_Plans", "Gases_Covered",
"Scope_1_Target", "Scope_2_Target", "Scope_3_Target", "Scope_3_Planning",
"Carbon_Credits", "Offset_Percentage", "Offset_Details", "UN_Membership",
"Methodology"
]
df_paper = df_paper.dropna(subset=["Company"])
net_zero_years_paper= df_paper["Target_Status"].str.extract(r"(\d{4})", expand=Fa
transition_plans_paper = df_paper["Transition_Plan_Timing"].dropna()
medium_term_paper = transition_plans_paper.str.contains("medium term", case=False
long_term_paper = transition_plans_paper.str.contains("long term", case=False).su
scopes_paper = {
"Scope 1": df_paper["Scope_1_Target"].str.contains("Yes", case=False, na=Fals
"Scope 2": df_paper["Scope_2_Target"].str.contains("Yes", case=False, na=Fals
"Scope 3": df_paper["Scope_3_Target"].str.contains("Yes", case=False, na=Fals
}
gases_covered_paper = df_paper["Gases_Covered"].str.contains("Yes", case=False, n
gases_not_covered_paper = len(df_paper) - gases_covered_paper
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
17/35

```

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [40]:

```

plt.figure(figsize=(4, 4)) #esto lo he puesto para que el gráfico mida lo mismo d
#una columna y quedaba raro tan alargado.
plt.hist(net_zero_years_paper, color="lightgreen", bins=5, rwidth=0.9)
plt.title("Años Objetivo Net Zero. Industria Papel.")
plt.xlabel("Año")
plt.ylabel("Número de Empresas")
plt.xticks([2040, 2050])
plt.grid(axis="y", alpha=0.2)
plt.yticks(range(0, 6, 1)) # Esto lo he hecho para que me vaya el eje y de 1 en
#hasta 6 para asegurarme de que me coge todas.
plt.show()
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
18/35

```

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [41]:

```

# Planes de transición (mediano vs largo plazo)
plt.figure(figsize=(7, 2))
plt.bar(["Medio Plazo", "Largo Plazo"], [medium_term_paper, long_term_paper], col
plt.title("Número de Empresas con Planes de Transición. Industria Papel.")
plt.yticks(range(0, max(medium_term_paper, long_term_paper) + 1, 1)) #Esto lo he h
#que se vean todas las que tienen los objetivos. Como son pocas puede ir de 1 en 1
plt.ylabel("Número Empresas")
plt.show()

```

```

localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
19/35

```

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [42]:

```

lista_gases_paper = df_paper["Gases_Covered"].dropna().str.split("\n").explode().
# Filtrar gases no vacíos
lista_gases_paper = lista_gases_paper[lista_gases_paper != ""]
# Contar la frecuencia de cada gas
contador_gases_paper = lista_gases_paper.value_counts()
# Seleccionar los 10 gases más mencionados
gases_fundamentales_paper = contador_gases_paper.head(10)
# Generar el gráfico de barras
plt.figure(figsize=(7, 2))
gases_fundamentales_paper.plot(kind="bar", color="lightcoral", edgecolor="black")
plt.title("Gases Más Relevantes en la Industria Papel")
plt.xlabel("Gases")
plt.ylabel("Frecuencia")
plt.xticks(rotation=45, ha="right", fontsize=8)
plt.grid(axis="y", linestyle="--", alpha=0.7)
plt.show()

```

```

localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
20/35

```

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

6. Industria Acero

In [43]:

```
import pandas as pd
import matplotlib.pyplot as plt
data_steel = pd.ExcelFile("Steel database.xlsx")
df_steel = data_steel.parse("Hoja1", header=0)
df_steel.columns = [
"Company", "Objectives", "Other_Details", "Target_Year", "Target_Status", "Net_
"Next_Status", "Transition_Plan", "Transition_Plan_Timing", "CAPEX_Plans", "Ga
"Scope_1_Target", "Scope_2_Target", "Scope_3_Target", "Scope_3_Planning",
"Carbon_Credits", "Offset_Percentage", "Offset_Details", "UN_Membership",
"Methodology"
]
df_steel = df_steel.dropna(subset=["Company"])
net_zero_years_steel= df_steel["Target_Status"].str.extract(r"(\d{4})", expand=Fa
transition_plans_steel = df_steel["Transition_Plan_Timing"].dropna()
medium_term_steel = transition_plans_steel.str.contains("Medium term", case=False
long_term_steel = transition_plans_steel.str.contains("Long term", case=False).su
scopes_paper = {
"Scope 1": df_steel["Scope_1_Target"].str.contains("Yes", case=False, na=Fals
"Scope 2": df_steel["Scope_2_Target"].str.contains("Yes", case=False, na=Fals
"Scope 3": df_steel["Scope_3_Target"].str.contains("Yes", case=False, na=Fals
}
gases_covered_steel = df_steel["Gases_Covered"].str.contains("Yes", case=False, n
gases_not_covered_steel = len(df_steel) - gases_covered_steel
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
21/35
```

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [44]:

In [45]:

```
plt.figure(figsize=(4, 4)) #esto lo he puesto para que el gráfico mida lo mismo d
#una columna y quedaba raro tan alargado.
plt.hist(net_zero_years_steel, color="lightgreen", bins=5, rwidth=0.9)
plt.title("Años Objetivo Net Zero. Industria Acero.")
plt.xlabel("Año")
plt.ylabel("Número de Empresas")
plt.xticks([2030, 2050])
plt.grid(axis="y", alpha=0.2)
plt.yticks(range(0, 6, 1)) # Esto lo he hecho para que me vaya el eje y de 1 en
#hasta 6 para asegurarme de que me coge todas.
plt.show()
plt.figure(figsize=(7, 2))
plt.bar(["Medio Plazo", "Largo Plazo"], [medium_term_steel, long_term_steel], col
plt.title("Número de Empresas con Planes de Transición. Industria Acero.")
```

```

plt.yticks(range(0, max(medium_term_steel, long_term_steel) + 2, 1)) # Ajustar e
plt.ylabel("Número Empresas")
plt.show()
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
22/35
24/3/25, 22:12
Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook
In [46]:
import pandas as pd
import matplotlib.pyplot as plt
data_steel = pd.ExcelFile("Steel database.xlsx")
df_steel = data_steel.parse("Hoja1", header=0)
df_steel.columns = [
"Company", "Objectives", "Other_Details", "Target_Year", "Target_Status", "Net
"Next_Status", "Transition_Plan", "Transition_Plan_Timing", "CAPEX_Plans", "G
"Scope_1_Target", "Scope_2_Target", "Scope_3_Target", "Scope_3_Planning",
"Carbon_Credits", "Offset_Percentage", "Offset_Details", "UN_Membership",
"Methodology"
]
df_steel = df_steel.dropna(subset=["Company"])
# limpio los datos para que no haya problemas con los espacios
df_steel["Transition_Plan_Timing"] = df_steel["Transition_Plan_Timing"].str.strip
medium_term_steel = df_steel["Transition_Plan_Timing"].str.contains("medium term")
long_term_steel = df_steel["Transition_Plan_Timing"].str.contains("long term", na
# con esto verifico los valores de los planes de transicion
print("Medio Plazo:", medium_term_steel)
print("Largo Plazo:", long_term_steel)
# Extraer los años desde la columna Target_Status
net_zero_years_steel = df_steel["Target_Status"].str.extract(r"(\d{4})", expand=F
#con esto saco los años de los scope
scopes_paper = {
"Scope 1": df_steel["Scope_1_Target"].str.contains("yes", case=False, na=Fals
"Scope 2": df_steel["Scope_2_Target"].str.contains("yes", case=False, na=Fals
"Scope 3": df_steel["Scope_3_Target"].str.contains("yes", case=False, na=Fals
}
gases_covered_steel = df_steel["Gases_Covered"].str.contains("yes", case=False, n
gases_not_covered_steel = len(df_steel) - gases_covered_steel
plt.figure(figsize=(7, 2))
plt.bar(["Medio Plazo", "Largo Plazo"], [medium_term_steel, long_term_steel], col
plt.title("Número de Empresas con Planes de Transición. Industria Acero.")
plt.yticks(range(0, max(medium_term_steel, long_term_steel) + 2, 1)) # Eje Y aju
plt.ylabel("Número Empresas")
plt.show()
Medio Plazo: 5
Largo Plazo: 0
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
23/35

```

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [47]:

```
lista_gases_steel = df_steel["Gases_Covered"].dropna().str.split("\n").explode().
# Filtrar gases no vacíos
lista_gases_steel = lista_gases_steel[lista_gases_steel != ""]
# Contar la frecuencia de cada gas
contador_gases_steel = lista_gases_steel.value_counts()
# Seleccionar los 10 gases más mencionados
gases_fundamentales_steel = contador_gases_steel.head(10)
# Generar el gráfico de barras
plt.figure(figsize=(7, 2))
gases_fundamentales_steel.plot(kind="bar", color="lightcoral", edgecolor="black")
plt.title("Gases Más Relevantes en la Industria del Acero")
plt.xlabel("Gases")
plt.ylabel("Frecuencia")
plt.xticks(rotation=45, ha="right", fontsize=8)
plt.grid(axis="y", linestyle="--", alpha=0.7)
plt.show()
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
24/35
```

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [56]:

```
import matplotlib.pyplot as plt
import numpy as np
# Datos existentes los pongo en listas
sectores = ["Aluminio", "Químicos", "Cemento", "Petróleo", "Papel", "Acero"]
anios = [2025, 2030, 2035, 2040, 2045, 2050]
# Numero de empresas por año objetivo para cada sector
datos_empresas = {
    "Aluminio": [2, 1, 1, 0, 0, 1],
    "Químicos": [0, 4, 1, 0, 0, 2],
    "Cemento": [0, 2, 0, 0, 0, 2],
    "Petróleo": [0, 0, 0, 0, 0, 5],
    "Papel": [0, 0, 0, 1, 0, 2],
    "Acero": [0, 3, 0, 0, 0, 2]
}
colores = {
    "Aluminio": '#4682B4',
    "Químicos": '#B0C4DE',
    "Cemento": '#8FBC8F',
    "Petróleo": '#FFD700',
    "Papel": '#6A5ACD',
    "Acero": '#FF6347'
}
plt.figure(figsize=(12, 8))
```

```

base = np.zeros(len(anios))
# barras apiladas y añadir números
for sector, color in colores.items():
valores = datos_empresas[sector]
plt.bar(anios, valores, bottom=base, label=sector, color=color, alpha=0.85)
# Añadir texto dentro de cada sección de la barra
for i, valor in enumerate(valores):
if valor > 0: # solo aparece si el valor es mayor que 0
plt.text(anios[i], base[i] + valor / 2, str(valor), ha='center', va='
base += valores # Actualizar la base para la siguiente capa de la pila
plt.title("Número de Empresas por Año Objetivo Net Zero y Sector", fontsize=16, f
plt.xlabel("Años Objetivo", fontsize=14)
plt.ylabel("Número de Empresas", fontsize=14)
plt.xticks(anios, fontsize=12)
plt.yticks(fontsize=12)
plt.legend(title="Sectores", fontsize=10, loc='upper left')
plt.grid(axis='y', linestyle='--', alpha=0.7)
plt.tight_layout()
plt.show()
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
25/35
24/3/25, 22:12
Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook
26/35
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
24/3/25, 22:12
Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook
In [61]:
import matplotlib.pyplot as plt
import numpy as np
# Datos: Frecuencia de gases por sector
sectores = ["Aluminio", "Químicos", "Cemento", "Petróleo", "Papel", "Acero"]
gases = ["CO2", "CH4", "N2O", "PFCs", "HFCs", "SF6", "NF3"]
# Frecuencias por sector
frecuencias = {
"Aluminio": [4, 4, 3, 2, 2, 1, 1],
"Químicos": [4, 4, 3, 2, 2, 1, 1],
"Cemento": [3, 2, 2, 1, 0, 0, 0],
"Petróleo": [4, 4, 0, 0, 0, 0, 0],
"Papel": [4, 4, 3, 2, 2, 1, 1],
"Acero": [4, 4, 3, 1, 1, 0, 0]
}
# Crear una figura con subgráficos
fig, axes = plt.subplots(3, 2, figsize=(12, 10))
fig.suptitle("Gases Más Relevantes por Industria", fontsize=16, fontweight='bold')
# Configurar cada gráfico por sector
for ax, sector in zip(axes.flatten(), sectores):

```

```

valores = frecuencias[sector]
ax.bar(gases, valores, color='#FF6347', alpha=0.8)
ax.set_title(f"Industria del {sector}", fontsize=12)
ax.set_ylabel("Frecuencia", fontsize=10)
ax.set_xlabel("Gases", fontsize=10)
ax.tick_params(axis='x', labelrotation=45)
ax.set_yticks(np.arange(0, 5, 1)) # Etiquetas del eje Y de 0 a 4
ax.set_ylim(0, 4.5) # Límite superior ajustado para visibilidad de las barra
# Ajustar diseño
plt.tight_layout(rect=[0, 0, 1, 0.95])
plt.show()
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
27/35
24/3/25, 22:12
Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook
28/35
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
24/3/25, 22:12
Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook
VISUALIZACIONES 1ª PARTE "DESARROLLO"
Nº Empresas usadas para el análisis de datos
In [297]:
import pandas as pd
import matplotlib.pyplot as plt
sectores_todos = ["Aluminium", "Chemicals", "Concrete", "Oil", "Paper", "Steel"] #
bases_de_datos = [
"Aluminium database.xlsx", "Chemicals database.xlsx", "Concrete database.xlsx
"Oil database.xlsx", "Paper databse.xlsx", "Steel database.xlsx"
]
numero_empresas = [] #AQUI Voy a hacer una lista que me cuente el número de empre
#en cada base datos de excel que le he metido a python
for base_de_datos in bases_de_datos:
datos_excel = pd.read_excel(base_de_datos)
empresas = datos_excel["Company"].dropna() #esto lo pongo para que no me cuen
numero_empresas.append(len(empresas)) # Contar empresas
# Crear el gráfico
plt.bar(sectores, numero_empresas, color="darkkhaki", edgecolor="black")
plt.title("Número de Empresas Analizadas por Sector")
plt.xlabel("Sector")
plt.ylabel("Número de Empresas")
plt.xticks(rotation=45)
plt.grid(axis="y", linestyle="-", alpha=0.5)
plt.tight_layout()
plt.show()
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
29/35
24/3/25, 22:12

```

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook
30/35

localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook
In [64]:

```
import pandas as pd
import matplotlib.pyplot as plt
# bases de datos de todos los sectores
dataframes = [df_alum, df_chem, df_concrete, df_oil, df_paper, df_steel]
#contadores
scope_counts = {"Scope 1": 0, "Scope 2": 0, "Scope 3": 0}
# Contar el compromiso en cada Scope en todas las bases de datos
for df in dataframes:
    scope_counts["Scope 1"] += df["Scope_1_Target"].str.contains("Yes", case=False)
    scope_counts["Scope 2"] += df["Scope_2_Target"].str.contains("Yes", case=False)
    scope_counts["Scope 3"] += df["Scope_3_Target"].str.contains("Yes", case=False)
# Crear un gráfico de barras para la cobertura global
plt.figure(figsize=(7, 4))
plt.bar(scope_counts.keys(), scope_counts.values(), color=["lightblue", "lightgreen"])
plt.title("Cobertura de Compromisos en Alcances (Scope 1, 2, 3)")
plt.xlabel("Alcances")
plt.ylabel("Número de Empresas")
plt.ylim(0, max(scope_counts.values()) + 5) # Ajustar el rango del eje Y
plt.grid(axis="y", alpha=0.3)
plt.show()
```

localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
31/35

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook
GRÁFICO DATOS INE

In [8]:

```
import pandas as pd
import matplotlib.pyplot as plt
file_path = 'Análisis Big Data sectores INE.xlsx'
# Cargo archivo
try:
    data = pd.ExcelFile(file_path)
    print("Hojas disponibles en el archivo:", data.sheet_names)
    df = data.parse(data.sheet_names[0]) #para que me coja la primera hoja del ex
    # Mostrar las primeras filas del archivo para verificar los datos
    print("Primeras filas del archivo:")
    print(df.head())
    # Filtrar sectores clave y sus porcentajes desde las columnas relevantes
    sectores = ['Energía y agua', 'Petróleo y químicos', 'Metales y minería', 'Pr
    porcentajes = [45.87, 57.35, 58.75, 44.65, 36.49] # Ajusta los datos aquí si
# crear dataframe
```

```

df_filtrado = pd.DataFrame({'Sector': sectores, 'Porcentaje': porcentajes})
plt.figure(figsize=(10, 6))
bars = plt.bar(df_filtrado['Sector'], df_filtrado['Porcentaje'], color='darkred')
plt.title('Porcentaje de empresas que analizan Big Data por sector industrial')
plt.ylabel('Porcentaje (%)', fontsize=12)
plt.xlabel('Sector industrial', fontsize=12)
plt.ylim(0, 70)
plt.xticks(rotation=45, fontsize=10)
plt.grid(axis='y', linestyle='--', alpha=0.7)
plt.tight_layout()
# % encima de las barras
for bar in bars:
    height = bar.get_height()
    plt.text(bar.get_x() + bar.get_width() / 2, height + 1, f'{height:.2f}%',
             ha='center', va='bottom', size=10)
plt.show()
except FileNotFoundError:
    print("Error: El archivo no se encuentra en la carpeta actual. Verifica que e
except Exception as e:
    print(f"Error inesperado: {e}")
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
32/35

```

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

Hojas disponibles en el archivo: ['tabla-49864']

Primeras filas del archivo:

Resultados nacionales Unnamed: 1 Unnamed: 2 \

| | | | |
|---|---|-----|-----|
| 0 | Empresas con 10 o más empleados: Las TIC en la... | NaN | NaN |
| 1 | | NaN | NaN |
| 2 | Análisis de Big Data | NaN | NaN |
| 3 | Unidades: porcentajes | NaN | NaN |
| 4 | | NaN | NaN |

Unnamed: 3 Unnamed: 4

| | | |
|---|-----|-----|
| 0 | NaN | NaN |
| 1 | NaN | NaN |
| 2 | NaN | NaN |
| 3 | NaN | NaN |
| 4 | NaN | NaN |

localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
33/35

24/3/25, 22:12

Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook

In [24]:

```

import matplotlib.pyplot as plt
import numpy as np
# Datos de los sectores y categorías
sectores = [
    "Energía y agua",

```

```

"Petróleo y químicos",
"Metales y minería",
"Productos papel y madera",
"Construcción"
]
categorias = [
"Geolocalización",
"Datos sociales",
"Datos de sensores",
"Otros datos externos"
]
# Datos en porcentajes para cada sector y categoría
valores = np.array([
    [12.62, 54.78, 55.07, 31.44], # Energía y agua
    [17.60, 57.85, 74.50, 44.68], # Petróleo y químicos
    [18.62, 68.72, 66.88, 48.13], # Metales y minería
    [15.23, 57.85, 53.90, 35.86], # Productos papel y madera
    [12.45, 41.35, 39.20, 29.03], # Construcción
])
colores = ['rosybrown', 'lightsteelblue', 'darkkhaki', 'cadetblue', 'burlywood']
x = np.arange(len(categorias)) # Posiciones en el eje X para las categorías
width = 0.15 # Ancho de las barras
plt.figure(figsize=(12, 8))
for i, sector in enumerate(sectores):
    plt.bar(x + i * width, valores[i], width, label=sector, color=colores[i])
plt.title("Adopción de Big Data por sectores y categorías", fontsize=16, fontweig
plt.xlabel("Tipos de datos analizados", fontsize=14)
plt.ylabel("Porcentaje (%)", fontsize=14)
plt.xticks(x + width * (len(sectores) - 1) / 2, categorias, rotation=45, fontsize
plt.ylim(0, 100)
plt.legend(title="Sectores", fontsize=12)
plt.grid(axis='y', linestyle='--', alpha=0.7)
plt.tight_layout()
plt.show()
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb
34/35
24/3/25, 22:12
Codigo TFG ADE. Valeria Cagigas Gabriel. - Jupyter Notebook
35/35
localhost:8889/notebooks/TFG ADE/Codigo TFG ADE. Valeria Cagigas Gabriel..ipynb

```