


**UNIVERSIDAD NACIONAL DE LOMAS DE ZAMORA**

**FACULTAD DE INGENIERÍA**



**DOCTORADO EN INGENIERÍA**

**TESIS DOCTORAL**

**Nuevos modelos de negocio en el paradigma  
Industria 5.0. Inteligencia Artificial y Aprendizaje  
Automático para optimizar procesos industriales**

**Autor: Federico Walas Mateo**

**Director: Andrés Redchuk**

**Buenos Aires**

**2023**

# ÍNDICE

RESUMEN .....	3
AGRADECIMIENTOS.....	5
PRODUCCIÓN CIENTÍFICA DURANTE EL PERÍODO PREDOCTORAL.....	6
Listado de Acrónimos .....	8
CAPÍTULO 1 .....	10
1.1 Introducción.....	10
1.2 Antecedentes .....	10
1.3 Motivación.....	12
1.4 El Paradigma I4.0 y la complementación con el modelo I5.0.....	14
1.5 Algunas definiciones y premisas preliminares.....	16
1.6 Foco en los Recursos Humanos.....	16
1.7 Sistemas Ciberfísicos .....	18
1.8 Sistemas Tecnológicos que integran el paradigma I4.0 .....	19
1.9 Metodologías Ágiles.....	20
1.10 La economía conectada .....	21
1.11 Innovación abierta .....	22
1.12 Alcance de la tesis .....	23
1.13 Hipótesis de la tesis .....	26
CAPÍTULO 2 .....	28
2.1 Introducción.....	28
2.2 Generación de datos del proceso industrial, arquitectura integrada .....	28
2.3 Elementos de IIoT .....	30
2.4 Arquitectura de IIoT. Integración de IT y OT a través de IIoT .....	32
2.5 IIoT como facilitador de la AI/ML .....	33
2.6 La Inteligencia Artificial en los procesos industriales .....	35
2.7 Antecedentes de aplicación de AI/ML en la industria .....	40
2-8 Oportunidades para el desarrollo de una nueva metodología para la incorporación de IA/ML en el ámbito Industrial.....	44
CAPÍTULO 3 .....	48
3.1 Introducción.....	48
3.2 Nuevos Modelos de Negocios. ....	49
3.3 Metodologías de desarrollo de software a través de bajo código (Low Code) .....	52
3.4 Solución propuesta a través del nuevo modelo de negocio .....	54
3.5 Metodologías ágiles como facilitadoras del cambio .....	56

3.6 Metodología Lean Startup como alternativa para Gestión de Proyectos Ágiles ..	58
3.7 Propuesta metodológica .....	60
3.8 Validación de la metodología y el nuevo modelo de negocio en casos de aplicación en la industria .....	61
3.9. Resultados y discusión sobre los casos.....	76
CAPÍTULO 4 .....	80
4.1 Introducción.....	80
4.2 Conclusiones .....	80
4.3 Futuras Líneas de Investigación .....	82
REFERENCIAS .....	89

## **RESUMEN**

La tesis que se presenta a continuación se desarrolla en el marco de una vertiginosa evolución de los sistemas de producción hacia un nuevo paradigma conocido como Industria 5.0. Este nuevo modelo, que surge como una versión superadora del modelo Industria 4.0, impulsa a empresas productivas tradicionales a migrar hacia entornos de producción inteligentes, que demandan nuevas soluciones para adaptar los procesos productivos e incorporar nuevas prácticas que permitan generar mayor competitividad por parte de las empresas industriales. La evolución hacia un nuevo paradigma desde el modelo Industria 4.0, se puede explicar por la dinámica de los sistemas productivos, la digitalización, el aumento de la complejidad en los mercados, la necesidad de dar respuesta a la emergencia ambiental, entre otras cuestiones.

Mientras que Industria 4.0 apunta a generar sistemas productivos cognitivos, la naciente era de la Industria 5.0 propone una evolución desde la anterior, para establecer cadenas de valor globales más resilientes, sostenibles y circulares que beneficien a la sociedad en su conjunto. Además, el nuevo marco pone el foco en las personas que intervienen en los procesos industriales, y busca lograr procesos productivos que minimicen el impacto ambiental hacia la neutralidad de la huella de carbono (CO<sub>2</sub>).

En este escenario, surgen oportunidades para la adopción de nuevos modelos de negocio, y modelos operativos que deben adaptarse al marco en el que operan empresas industriales tradicionales, muchas de ellas establecidas y con prácticas, y una cultura organizacional que se desarrollan desde hace más de 100 años como los casos de la industria del acero, la minería, y la industria de procesos en general.

El trabajo que se presenta en esta tesis aborda oportunidades y riesgos que surgen bajo el paradigma digital en la industria, particularmente a partir del potencial disruptivo que ofrece la Inteligencia Artificial, y las demandas desde la industria para generar procesos más eficientes.

Como ejemplo de oportunidades en los modelos de negocio, es evidente que la digitalización bajo el modelo Industria 4.0/industria 5.0, y las ventajas de la adopción de Internet Industrial de las Cosas, permite una respuesta más rápida

a las demandas de los clientes, aumenta la flexibilidad permitiendo la adaptabilidad a los procesos de fabricación, permiten empoderar a las personas a partir de contar con mayor información, y proporciona una enorme cantidad de herramientas para la mejora de la calidad en los procesos, entre otras ventajas.

En cuanto a los riesgos y aspectos críticos que considera este trabajo se encuentran la necesidad de considerar a las personas del piso de planta, la generación e integración de datos desde las operaciones, y la importancia de generar impacto, y un retorno de la inversión en plazos tan cortos como sea posible.

Esta tesis se focaliza en la adopción de la inteligencia artificial y el aprendizaje automático, y su integración con Internet Industrial de las Cosas en la Industria 4.0, y el emergente modelo Industria 5.0, a través de nuevos modelos de negocio, estrategia de plataformas de software de bajo código, y variantes de metodologías ágiles para gestionar el cambio. Estos son los temas en los que se centra el trabajo. Por otro lado, considera la integración de datos como impulsor de la optimización de procesos industriales para aumentar la competitividad, pero sobre todo para generar sustentabilidad ambiental, lograr democratizar el conocimiento en los procesos para empoderar a las personas, y por último alcanzar una mejor integración de las cadenas de valor.

El trabajo desarrolla casos de aplicación en industrias de procesos, que se consideran relevantes con respecto a la posibilidad de adopción de soluciones de inteligencia artificial. En todos los casos buscaban la optimización de procesos industriales en el marco del paradigma de Industria 4.0/5.0.

Los casos demuestran los beneficios de implementar soluciones que permiten generar inteligencia en los procesos industriales a partir del uso de los datos de los procesos, integrando soluciones de Internet Industrial de las Cosas con plataformas de inteligencia artificial y aprendizaje automático.

Por lo tanto, se muestra como un nuevo modelo de negocio basado en una plataforma de software de bajo código, adoptado a través de la metodología Lean Startup, permite facilitar la adopción de soluciones de Inteligencia Artificial y Aprendizaje Automático en procesos industriales.

## **AGRADECIMIENTOS**

Esta tesis llegó en un momento especial de mi carrera y mi vida, grandes personas y excelentes profesionales me han acompañado e impulsado para alcanzar este hito. Son muchos nombres de personas generosas que me han apoyado, y de alguna manera han aportado para generar este trabajo.

En primer lugar, quiero agradecer al Dr. Oscar Pascal, quien me abrió las puertas de la Facultad de Ingeniería de la UNLZ para comenzar con esta maravillosa experiencia del Doctorado, y quien me puso en manos del Dr. Andrés Redchuk, que sin conocerme accedió a ser mi Director de tesis, y se convirtió en mucho más que eso. Muchas Gracias Andrés por tu generosidad, compromiso, tus consejos, y todo el tiempo que me has dedicado para lograr esta tesis.

Gracias a Elena por estar siempre, por enseñarme a celebrar el conocimiento y su valor para ser libre y el crecimiento personal. Gracias Claudia por confiar siempre, por el amor y el apoyo incondicional en esta aventura en todo momento, que junto a Delfina y Bianca estuvieron siempre pendientes, y sacrificaron tiempo que no les pude dedicar.

No quiero dejar de agradecer a Julián Tornillo, y al equipo de la cátedra de PCOP de la Facultad de Ingeniería de la UNLZ.

Y a los amigos que siempre estuvieron y aportaron, a todos ellos y ellas que me impulsaron a llegar hasta acá.

# PRODUCCIÓN CIENTÍFICA DURANTE EL PERÍODO PREDOCTORAL

A continuación, se detalla la producción científica del doctorando Federico Walas Mateo en el periodo predoctoral.

## PUBLICACIONES EN REVISTAS INTERNACIONALES

F. Walas Mateo, A. Redchuk. (2021). **The Emergence of New Business and Operating Models under the Industrial Digital Paradigm. Industrial Internet of Things, Platforms, and Artificial Intelligence/Machine Learning.** Journal of Mechanics Engineering and Automation 11 (2021) 54-60 doi: 10.17265/2159-5275/2021.02.004.

F. Walas Mateo, A. Redchuk. (2021). **New business and operating models under Industry 4.0 paradigm to boost industrial Process Optimization. Industrial Internet of Things (IIoT) and Artificial Intelligence/Machine Learning (AI/ML).** American Journal of Engineering Research (AJER), vol. 10(8), 2021, pp. 265-270.

<https://www.ajer.org/papers/Vol-10-issue-8/ZC1008265270.pdf>

F. Walas Mateo, A. Redchuk. (2021). **A review of IIoT/IoT and AI/ML as Process Optimization driver under industry 4.0 model. Journal of Computer Science & Technology (JCS&T).** Vol 21. ed. 2, pp 170-176. <https://doi.org/10.24215/16666038.21.e15>

**Revista Indexada en Scopus y en Emerging Source Citation Index.**

A. Redchuk, F. Walas Mateo (2022). **New Business Models on Artificial Intelligence—the Case of the Optimization of a Blast Furnace in the Steel Industry by a Machine Learning Solution.** Applied System Innovation. 5(1):6. <https://doi.org/10.3390/asi5010006>.

**Revista Indexada en Scopus y Emerging Source Citation Index.**

A. Redchuk, F. Walas Mateo, G. Pascal, JE Tornillo. (2022) **Contributions of innovation ecosystems in the adoption of the industry 4.0 model in SMEs, a bibliometric study.** International Journal of Science and Research (IJSR). ISSN: 2319-7064. Vol. 11. Nro 4. Pag. 1303.

<https://www.ijsr.net/archive/v11i4/SR22329015143.pdf>

F. Walas Mateo, A. Redchuk. (2022). **Artificial Intelligence as a Process Optimization driver under industry 4.0 framework and the role of IIoT, a bibliometric analysis. – JIIM.** Journal of Industrial Integration and Management Innovation & Entrepreneurship. ISSN (print): 2424-8622 | ISSN (online): 2424-8630. <https://doi.org/10.1142/S2424862222500130>

**Revista Indexada en Scopus y Emerging Source Citation Index, y SJR Q1.**

A. Redchuk, F. Walas Mateo, G. Pascal, JE Tornillo. (2023). **Adoption Case of IIoT and Machine Learning to Improve Energy Consumption at a Process**

**Manufacturing Firm, under Industry 5.0 Model.** *Big Data and Cognitive Computing*. 2023; 7(1):42. <https://doi.org/10.3390/bdcc7010042>  
**Revista Indexada en Scopus, Emerging Source Citation Index, y SJR Q1.**

F. Walas Mateo, A. Redchuk, J.E. Tornillo. (2023). **Smart manufacturing and new business models in mining. Adoption Case of Machine Learning to improve a Copper Milling Process.** *Journal of Mechatronics and Robotics* Volume 7(1):42-47. DOI: 10.3844/jmrsp.2023.42.47

## **PUBLICACIONES EN CONGRESOS**

F. Walas Mateo, A. Redchuk. (2021). **The Emergence of New Business and Operating Models under the Industrial Digital Paradigm. Industrial Internet of Things, Platforms, and Artificial Intelligence/Machine Learning.** International Conference of Production Research-Americas (ICPR-Americas). Editorial UNS. ISSN 2619-1865. Argentina.  
[https://www.matematica.uns.edu.ar/ipcra/pdf/icpr\\_americas\\_2020\\_proceedings.pdf](https://www.matematica.uns.edu.ar/ipcra/pdf/icpr_americas_2020_proceedings.pdf)

F. Walas Mateo, A. Redchuk. (2021). **Artificial Intelligence and Machine Learning as a Process Optimization driver under Industry 4.0 framework, the role of the people in the process.** Global Conference on Engineering Research (GLOB CER). Bandirma Onyedi Eylul University. 2-5 June 2021. Turkey. ISBN: 978-625-44365-9-8.  
[https://www.globcer.org/files/ugd/e04d41\\_afb86d75cfb84935a0c0073fa5768c00.pdf](https://www.globcer.org/files/ugd/e04d41_afb86d75cfb84935a0c0073fa5768c00.pdf)

F. Walas Mateo, A. Redchuk. (2021). **IIoT or IoT and Artificial Intelligence as a Process Optimization driver under industry 4.0 framework.** IX Jornadas de Cloud Computing, Big Data & Emerging Topics. III-LIDI. UNLP. 22 al 25 de junio de 2021. La Plata. Argentina.  
<http://sedici.unlp.edu.ar/handle/10915/128267>

F. Walas Mateo, A. Redchuk. (2021). **La necesidad de desarrollo de Ecosistemas de Innovación para facilitar la adopción del modelo Industria 4.0 en PyMEs.** Trabajo completo aceptado y presentado en el (5° Congreso Argentino de Ingeniería (CADI), el 3° Congreso Latinoamericano de Ingeniería (CLADI) y el 11° Congreso Argentino de Enseñanza de la Ingeniería (CAEDI)). ISBN 978-987-88-1872-6.  
[https://www.researchgate.net/publication/355339220\\_Actas\\_Congreso\\_Argentino\\_y\\_Latinoamericano](https://www.researchgate.net/publication/355339220_Actas_Congreso_Argentino_y_Latinoamericano)

F. Walas Mateo and A. Redchuk. (2021). **Searching for Key Topics around Artificial Intelligence and Machine Learning as a Process Optimization Driver.** IEOM 2021, Monterrey Conference 6th North American Industrial Engineering and Operations Management Conference. November 2-5, 2021. Monterrey, Mexico. Actualmente en los proceedings del congreso bajo el #164. **ISSN: 2169-8767 (U.S. Library of Congress), ISBN: 978-1-7923-6130-2.**  
<http://www.ieomsociety.org/monterrey2020/proceedings/>



F. Walas Mateo, A. Redchuk, **Process Optimization in the Steel Industry using Machine Learning adopting an Artificial Intelligence Low Code Platform**. X Jornadas de Cloud Computing, Base de Datos y Emerging Topics (JCC-BD&ET) de la UNLP 30/6 2022. Publicado en Short papers of the 10th Conference on Cloud Computing, Big Data & Emerging Topics, Facultad de Informática UNLP. ISBN: 978-950-34-2126-0.  
<http://sedici.unlp.edu.ar/handle/10915/139373>

F. Walas Mateo, A. Redchuk, J.E. Tornillo. (2022). **Industry 5.0 and new business models in mining. Adoption Case of Machine Learning to optimize the process at a copper Semi Autogenous Grinding (SAG) Mill.**. 5th IEOM European Conference on Industrial Engineering and Operations Management, Rome, Italy, July 26-28, 2022.  
<http://ieomsociety.org/rome2022/proceedings/>

F. Walas Mateo, A. Redchuk, J.E. Tornillo. (2022). **Industry 5.0 and sustainability. Adoption Case of Machine Learning to improve energy consumption at a process industry**. 2nd GLOBAL CONFERENCE on ENGINEERING RESEARCH, GLOB CER '22. Turquia.  
[https://www.globcer.org/\\_files/ugd/e04d41\\_26730e283a894ef09da9055dc7538fbb.pdf](https://www.globcer.org/_files/ugd/e04d41_26730e283a894ef09da9055dc7538fbb.pdf)

F. Walas Mateo, A. Redchuk, J.E. Tornillo. (2022). **Incorporando el paradigma Industria 4.0 en el Ecosistema Industrial Regional CADI/CAEDI 2022**.  
[https://scholar.google.com/citations?view\\_op=view\\_citation&hl=es&user=daFPTscAAAAJ&cstart=20&pagesize=80&citation\\_for\\_view=daFPTscAAAAJ:r0BpntZqJG4C](https://scholar.google.com/citations?view_op=view_citation&hl=es&user=daFPTscAAAAJ&cstart=20&pagesize=80&citation_for_view=daFPTscAAAAJ:r0BpntZqJG4C)

## Listado de Acrónimos utilizados

<b>Acrónimo</b>	<b>Significado</b>
AI	Inteligencia Artificial
ML	Aprendizaje Automático
LCP	Plataforma Bajo Código
I4.0	Industria 4.0
I5.0	Industria 5.0
IoT	Internet de las Cosas
IIoT	Internet Industrial de las Cosas
MES	Manufacturing Execution System
HMI	Interfaces Hombre Máquina
SCADA	Sistemas de Supervisión Control y Adquisición de Datos
PLC	Controladores Lógicos Programables
CPS	Sistema Ciber Físico
AGV	Vehículos de Guiado Automático
MRP	Planificación de recursos Materiales
CIM	Manufactura Integrada por Computadora
BOM	Bill of Materials
ERP	Enterprise Resource Planning
TICs	Tecnología de Información y Comunicaciones
ODS	Objetivos de Desarrollo Sustentable de las Naciones Unidas
RFID	Identificación por Radio Frecuencia
API	Interfaz de la Programación de la Aplicación
MVP	Producto Mínimo Viable

GUI	Interfaz Gráfica del Usuario
APM	Gestión de Proyecto a través de Metodologías Ágiles
SaaS	Software como Servicio
ID	Identificador Único de Cliente
IP	Protocolo de Internet
KPI	Indicador Clave de Desempeño
IT	Tecnología de la Información
OT	Tecnología de Operaciones
SOA	Arquitectura Orientada a Servicios

# **CAPÍTULO 1 –Industria 4.0 y 5.0, conceptos asociados, y nuevos modelos de negocio.**

## **1.1 Introducción**

En este capítulo se presentan los fundamentos sobre los que se desarrollará el trabajo. En primer término, se detalla la motivación que da lugar a la tesis doctoral que se presenta. Más adelante se establece el marco conceptual sobre el que se genera la investigación, se establece el alcance, y las hipótesis consideradas para abordar el desafío tecnológico que considera la producción doctoral.

## **1.2 Antecedentes**

A continuación, se presenta una sucinta descripción de los antecedentes que preceden la irrupción de I4.0/I5.0. Se puede considerar que la producción industrial comenzó a partir de la primera revolución Industrial o Industria 1.0, que surge a finales del siglo XVIII a partir de la aparición de dispositivos mecánicos accionados a través del vapor como vector energético.

La segunda revolución industrial o Industria 2.0 irrumpe en el último cuarto del siglo XIX, y se caracterizó por la introducción de líneas de montaje para la producción en masa a través del modelo que luego se conocería como “Fordista”. Esto se profundizó con las prácticas recomendadas a través de los “Principios de la Administración Científica” que desarrolló Frederick W. Taylor. La aparición del teléfono, la electricidad, el uso intensivo de combustibles fósiles, y la mecanización son algunas de las características de este modelo industrial que caracterizó la primera parte del siglo XX.

La tercer revolución industrial o Industria 3.0 comenzó en la segunda mitad del siglo XX, a partir del desarrollo de la electrónica, y la disrupción que significó la aparición del transistor. Esto permitió en principio, un mayor nivel de automatización a partir de la utilización de robots, tecnología de la información y microprocesadores. La mayoría de estas iniciativas del siglo XX están estrechamente relacionadas con tecnologías de la información y la comunicación (TICs). Algunos emergentes de este paradigma son los Sistemas Integrados por Computadora (CIM), Planificación de recursos de Manufactura

asistido por computadora (MRP), Diseño Asistido por Computadora (CAD), y los Sistemas de Manufactura Flexibles, entre otros.

*“Uno puede ver la era de las computadoras por todas partes salvo en las estadísticas de productividad”. Robert Solow. 1987*

Actualmente estamos atravesando la madurez del modelo Industria 4.0, concepto que se establece hace un poco más de 10 años en Alemania. Este paradigma o cuarta revolución industrial se basa en la idea de fusionar lo físico y lo virtual a través de sistemas ciberfísicos e interconectando humanos, máquinas y dispositivos a través del Internet de las Cosas (IoT). Por lo tanto, es posible la interconexión horizontal y vertical en toda la cadena de valor, desde el cliente hasta el proveedor, en todo el ciclo de vida del producto, y a través de diferentes departamentos funcionales conformando nuevas redes de valor y ecosistemas.

Mientras esto ocurre, se observa la aparición del paradigma Industria 5.0, producto de la evolución incremental del modelo anterior. Sin rasgos disruptivos, el modelo 5.0 se diferencia del anterior a partir de una mayor focalización en valores sociales y ecológicamente relevantes. Este paradigma reconoce el poder de la industria para lograr beneficios sociales más allá del empleo y el crecimiento para convertirse en un proveedor de prosperidad, al hacer que la producción respete los límites de nuestro planeta, y poner el bienestar de los trabajadores de la industria en el centro del proceso de producción. La Tabla 1 que se presenta a continuación, pretende sintetizar los conceptos expresados en los párrafos anteriores.

En este marco de transformación hacia el paradigma Industria 5.0 es donde se origina el trabajo de Tesis que se presenta a continuación.

Industria 1.0	1780	Producción industrial basada en máquina de vapor y energía hidráulica.	Mecanización, energía a través del vapor y el agua.	Primer telar mecánico.
Industria 2.0	1870	Producción en masa en líneas de producción. Aparición de la energía eléctrica.	Electricidad, División del trabajo, y producción en masa.	Primera línea de ensamblado en serie.
Industria 3.0	1970	Automatización con electrónica e Informática.	Automatización, Electrónica, Sistemas Informáticos.	Primer Controlador Lógico Programable.
Industria 4.0	2011	Dispositivos conectados, Analítica de datos, Sistemas ciberfísicos.	Digitalización, Cobots, IoT; Big Data, Computación en la Nube.	Sistemas ciberfísicos.
Industria 5.0	Actualmente	Cooperación entre personas sistemas tecnológicos para mejorar productos y servicios, foco en sustentabilidad ambiental.	Personalización, empoderamiento de las personas a través de la Inteligencia Artificial, Sustentabilidad.	Personas empoderadas en el foco de los sistemas productivos. Procesos industriales amigables con el medio ambiente.

Tabla 1. Desde industria 1.0 a Industria 5.0. Síntesis de rasgos característicos de cada modelo industrial.

### 1.3 Motivación

El ámbito productivo enfrenta importantes desafíos para adaptarse a las condiciones de borde que impone la economía del conocimiento, y la complejidad del entorno de negocios actual. Por un lado, las empresas necesitan lograr una mayor eficiencia para ingresar y permanecer en cadenas de valor globales, responder de manera eficiente a la volatilidad y complejidad de los mercados, y por otro lado hacer un uso óptimo de los recursos para minimizar la huella de CO<sub>2</sub> que generan los procesos industriales, entre otros.

En ese marco la inteligencia artificial (AI) ofrece oportunidades a través de nuevos modelos de negocio (Redchuk & Walas Mateo, 2022), para transformar procesos productivos tradicionales hacia sistemas más inteligentes y eficientes. Pfau & Rimpp (2021) destacan el potencial disruptivo de la IA y, más específicamente, el aprendizaje automático (ML) para generar nuevos modelos de negocios y oportunidades para los emprendedores.

Da Silva et al (2019), plantean que las oportunidades para el desarrollo de industrias inteligentes, y la evolución de los sistemas productivos hacia esquemas que maximicen la competitividad es resultado de la demanda de tecnologías y procedimientos más eficientes, estándares de calidad y reducción de costos, así como la innovación tecnológica. Por otro lado, el artículo visibiliza

varios temas relacionados con la Industria 4.0 (I4.0); el enfoque principal de este paradigma de producción es generar en las industrias existentes procesos más inteligentes y adaptables, con un óptimo uso de los recursos.

Los conceptos del párrafo anterior se refuerzan al revisar los Objetivos de Desarrollo Sostenible (ODS) de la Organización de las Naciones Unidas (ONU) (2015), en particular los referidos a la innovación industrial, el consumo y la producción responsables, y la mitigación del cambio climático. Muller (2020) observa que la generación de valor puede realizarse en un modo más eficiente, personalizada, de mayor calidad, orientada al servicio, trazable, resiliente y flexible. El mantenimiento estará conectado a producción de una manera diferente a la anterior, resultando en una cadena integrada que cubre el ciclo de vida completo. Generará beneficios en lo económico, ecológico y social, relacionados con el Triple Impacto del desarrollo sostenible.

Por otro lado, la irrupción de la tecnología de Internet Industrial de las Cosas (IIoT), permite integrar datos generados en el piso de planta para utilizarlos en la gestión y de esta manera facilitar la optimización de procesos. Walas Mateo y Redchuk (2022), presentan un trabajo donde analiza el concepto de inteligencia artificial y aprendizaje automático (AI/ML) como herramienta para la optimización de procesos dentro del modelo Industria 4.0. Esto es un ítem que contribuye a la motivación para el desarrollo de la presente tesis.

Por último, la evolución del modelo I4.0 hacia un nivel superior que se conoce como Industria 5.0 (I5.0) abre nuevos espacios para avanzar en la investigación sobre cómo se adoptan soluciones que permitan a las empresas industriales internalizar estos nuevos paradigmas productivos. Algunos autores (Di Nardo & Yu (2020); Doyle-Kent & Kopacek (2021); Walas Mateo, Redchuk, & Tornillo (2022); Chander et. al (2021)), conceptualizan el alcance y los objetivos del modelo I5.0. Los autores coinciden en que el nuevo marco busca la sostenibilidad junto con la integración en la cadena de valor, y la centralidad de las personas en el entorno productivo. Además, Muller (2020) y Breque et al (2021) observan que el modelo I5.0 es complementario al paradigma I4.0 que impulsa a las empresas hacia una industria sostenible, centrada en el ser humano y resiliente para adaptarse a las complejidades del entorno de negocio actual. Finalmente, ambos artículos destacan que el modelo I5.0 cambia desde

el enfoque de generar valor para los accionistas directos, hacia otro donde el valor sea generado para la sociedad toda.

Todo lo mencionado en los párrafos anteriores ha generado la inquietud para indagar y profundizar en metodologías y soluciones que faciliten la democratización de la IA y ML para optimizar procesos industriales en el marco del paradigma I5.0.

#### **1.4 El Paradigma I4.0 y la complementación con el modelo I5.0**

La tesis se origina considerando el marco del paradigma de la I4.0, en proceso de madurez, y el surgimiento de un nuevo paradigma que se conoce como el modelo I5.0. Se considerará la observación de Breque et al (2021) que destaca que el paradigma I5.0 no debe entenderse como una continuación cronológica del modelo I4.0 existente, o una alternativa al mismo. Según los autores es el resultado de un ejercicio prospectivo, una forma de enmarcar cómo la industria, las tendencias y necesidades emergentes de la sociedad coexistirán. Como tal, la I5.0 complementa y amplía las características distintivas de la I4.0. enfatiza aspectos que serán determinantes para situar a la industria en la sociedad del futuro; estos factores no son sólo de naturaleza económica o tecnológica, sino que también tienen importantes dimensiones ambientales y sociales.

La definición del concepto de I4.0, es amplio y difuso, y puede ser tratado desde múltiples miradas. Alguno de los enfoques más tecnocráticos están fuertemente vinculados a la tecnología informática y hardware aplicados a la industria, otros más vinculados a lo social se refieren al futuro del trabajo y el rol de las personas, si miramos la gestión de la tecnología y la innovación nos interesará la aparición de nuevos modelos de negocio, la innovación abierta y colaborativa, y desde lo organizacional aparecen las oportunidades de mejora en la Organización Industrial y la evolución de Cadenas Globales de Valor, entre otros.

Entonces podemos decir que la I4.0, no se trata solo de la industria. Se trata de una transformación general mediante la integración digital y la ingeniería inteligente. Se cita como el siguiente nivel de fabricación donde las máquinas se redefinirán en la forma en que se comunican y realizan funciones individuales (Muhuri et al. 2019).



Da Silva et al. (2019) afirma que las oportunidades para el desarrollo de industrias inteligentes se han expandido. Además de los procesos de producción, la evolución está impulsada por la demanda del mercado de tecnologías y la oportunidad para generar procesos más eficientes, estándares de calidad y reducción de costos, y también por la evolución tecnológica. En este artículo se discute una gran variedad de temas sobre la I4.0, uno de los enfoques principales del nuevo paradigma productivo es facilitar a las industrias existentes procesos más inteligentes y adaptables, con un mejor aprovechamiento de los recursos productivos.

Otro punto de vista sobre la I4.0 lo dan Ibarra et al. (2017), según este trabajo, el nuevo modelo ha sido introducido en el mundo de la manufactura por la creciente fusión de la Producción Industrial y las Tecnologías de la Información y la Comunicación (TIC). Este fenómeno está posibilitando la conexión de información, objetos y personas debido a la convergencia de los mundos físico y virtual (cibespacio) en forma de Sistemas Ciberfísicos, o *Cyber-Physical Systems* (CPS) en inglés. Esto entonces, está permitiendo la transformación de fábricas en entornos inteligentes que generan una enorme cantidad de datos.

Sarmiento et al. (2020) establecen que un principio clave del paradigma I4.0 es que los procesos y la maquinaria deben estar conectados en red y de esta forma colaborar en la recolección, intercambio y análisis de datos. De esta manera es posible predecir comportamientos futuros, y buscar soluciones óptimas a posibles problemas. En el artículo, los autores consideran que en la actualidad este principio comienza a ser alcanzable gracias al desarrollo de una serie de tecnologías que se encuentran en evolución, como la IA. Sobre los sistemas CPS sostienen que pueden ser optimizados con características de la tecnología de Internet Industrial de las Cosas (IIoT), lo que les brinda la capacidad de obtener continuamente información de sensores o procesos en toda la fábrica y enviarla de forma segura a los centros de datos (generalmente basados en la nube). Esta producción masiva de datos implica el desarrollo de nuevas herramientas basadas en técnicas de Big Data, para su almacenamiento, gestión y procesamiento.

Esta tesis pretende integrar y profundizar trabajos y experiencias previas en cuanto a los nuevos modelos de negocio y modelos operativos, que surgen vinculados al modelo I4.0 y evolucionan al paradigma emergente I5.0. En

particular se indaga sobre metodologías de adopción, rol del usuario y el cliente, entre otros aspectos. Un punto de partida para esta tesis aparece en el trabajo sobre el desarrollo de nuevos modelos de negocio, Walas Mateo (2020), y el artículo de Walas Mateo & Redchuk (2021). En esta tesis se tratarán los temas mencionados anteriormente con foco en torno a las soluciones en IIoT, inteligencia artificial / aprendizaje automático (AI/ML), y metodologías de adopción en el ámbito industrial para optimizar procesos.

### **1.5 Algunas definiciones y premisas preliminares**

En primer lugar, es necesario aclarar que el modelo I4.0 y su evolución al I5.0 abordan un número muy importante de conceptos y tecnologías. Para completar la introducción antes de focalizarnos en las hipótesis objeto de esta tesis, nos ocuparemos de realizar un breve desarrollo de los conceptos más significativos y relevantes que incorporan estos modelos productivos, para poder avanzar en el trabajo con mayor claridad.

Se podrá observar en este apartado la compleja naturaleza del paradigma I4.0, donde los elementos tecnológicos son solo una parte de este complejo modelo de producción. Por ejemplo, Ganzarain et al (2016), identifican 7 elementos centrales. Fábricas inteligentes, sistemas Ciberfísicos, auto organización, nuevos sistemas de distribución y compras, nuevos sistemas de desarrollo de productos y servicios, adaptación a las necesidades de las personas, y responsabilidad social corporativa. Aquí nos referiremos a los Recursos Humanos, Empresas de Base Tecnológica y startups, Innovación abierta, Sistemas Ciberfísicos, Economía conectada, y los sistemas tecnológicos.

### **1.6 Foco en los Recursos Humanos.**

Una de las primeras cuestiones que genera debate sobre el alcance e implicancias de los nuevos modelos productivos, es sobre el rol de las personas. Particularmente uno de los pilares del modelo I5.0 y producto de la evolución del anterior I4.0, está en la centralidad de las personas dentro del sistema productivo (Müller, 2020; Breque et al, 2021).

Breque et al (2021) afirman que una de las transiciones paradigmáticas más importantes que caracterizan a la Industria 5.0 es el cambio de enfoque del

progreso impulsado por la tecnología a un abordaje completamente centrado en el ser humano. Esto significa que la industria debe tener en cuenta las limitaciones sociales, con el objetivo de no dejar a nadie atrás. Esto tiene una serie de consecuencias, relacionadas con la seguridad y entorno de trabajo propicio, al respeto de los derechos humanos y a las competencias requeridas para los trabajadores.

Walas & Redchuk (2021) hablan de la oportunidad de complementación y la nueva definición del rol de las personas, trabajando en forma sinérgica con los sistemas tecnológicos. Para graficar esto es interesante citar lo que postula Peter Thiel en su libro de Cero a Uno (2014) sobre la relación Hombre y Máquina, y la oportunidad de optimizar los resultados de los procesos a través de la complementación entre estos dos actores del sistema. En este sentido dedica un capítulo del libro para dar visibilidad al potencial que existe en la complementación entre hombre y máquina. En ese trabajo presenta varios ejemplos de casos reales. El más interesante es el que llevó a la creación de la startup Palantir, que aborda temas de seguridad y que se nutre de un sistema híbrido hombre-máquina. Se trata de un sistema de software y hardware que procesa enormes cantidades de datos, y finalmente expertos analistas humanos toman decisiones.

Según Muller (2020), un pre requisito central para la I5.0 es que la tecnología esté al servicio de las personas, en lugar de ocurra a la inversa. En un contexto industrial, significa que la tecnología utilizada en la fabricación se adapta a las necesidades y la diversidad de los trabajadores de la industria, en lugar de hacer que el trabajador se adapte continuamente a la tecnología en constante evolución. el trabajador en el nuevo modelo estaría empoderado, y el ambiente de trabajo se transforma con más inclusión. Para lograr esto, los operarios deben involucrarse en los procesos de adopción de nuevas soluciones tecnológicas.

En línea con el párrafo anterior y para cerrar este tema por ahora, consideramos que es posible afirmar que los roles y el tipo de trabajo deberá adaptarse a nuevas formas de trabajo complementario e integrado con contenido de conocimiento técnico. El trabajo de Erol et al (2016) indica que las personas en un futuro escenario de producción necesitaran competencias específicas para

afrontar los nuevos desafíos relacionados con los desarrollos tecnológicos y organizacionales, y los modelos de negocio.

### **1.7 Sistemas Ciberfísicos**

Los sistemas Ciberfísicos o cyber-physical system (CPS), es la integración de máquinas y artefactos a través del software y la posibilidad de interacción con las personas. Los sistemas CPS, en sí mismos, son interdisciplinarios, incluyen sistemas físicos, mecánicos, hidráulicos, eléctricos, electrónicos, software y sensores. Esto permite generar procesos y productos inteligentes que puedan ser operados a distancia, contar con información en tiempo real, facilitar la complementación entre máquinas y personas para optimizar los procesos, integrar productos con información relevante, entre otras cuestiones.

El artículo de Ferrer et al. (2018) indica que los sistemas de manufactura están adoptando soluciones con mayor cantidad de sistemas de sensorización en base a abordajes de CPS para realizar monitoreo de procesos en tiempo real, optimizar la parametrización, y autoparametrización de máquina herramienta, robots y procesos industriales desde equipos individuales a entornos de producción globales.

Este concepto adquiere relevancia en el paradigma I4.0, en este sentido varios autores identifican a los CPS como uno de los pilares o rasgo distintivo de la I4.0, Basco et al (2018), Casalet (2018) y Brixner et al (2019), y Smit (2016), entre otros.

Según Casalet (2018) el desarrollo de los CPS se apoya en: i) los sistemas inteligentes, los servicios móviles y la computación ubicua, ii) los procesos de negocios basados en internet, como la tecnología de radio frecuencia para la identificación de dispositivos (RFID) utilizados de forma creciente en el comercio y la logística, generalmente integrados con proveedores de servicios en la nube, iii) las redes sociales y comunidades (web 2.0), incluidas las redes de conocimiento abierto (*open knowledge*).

Por último, asociado a este concepto aparece la tecnología de comunicaciones 5G, según Wollschlaeger et al (2017) esta tecnología generará un importante impacto integrando distintas plataformas y equipos de carácter heterogéneo con una altísima capacidad de procesamiento, entre otros.

## **1.8 Sistemas Tecnológicos que integran el paradigma I4.0.**

Los sistemas tecnológicos que son el núcleo central de la estrategia I4.0 son en general tecnologías que están disponibles desde fines del siglo pasado que han evolucionado, y se han convertido en accesibles por la baja de costos y aumento de capacidad de los procesadores. Esto que postulo Gordon Moore inicialmente en 1968, y se transformó en la ley que lleva su nombre permite explicar cómo la ingeniería computacional se ha incorporado a los sistemas productivos, y en la sociedad en general, de forma masiva.

Diversos autores (Muhuri et al. 2019, Da Silva et al. (2019), Basco et al (2018), Casalet (2018) y Brixner et al (2019), entre otros) coinciden en considerar a IIoT, Inteligencia Artificial, Impresión 3D, Blockchain, Computación en la Nube, Cobots o Robots Colaborativos, Realidad Aumentada/Virtual, Gemelo Digital, Ciberseguridad, como elementos tecnológicos comunes en el modelo I4.0.

Debe observarse que las soluciones tecnológicas no solo son aplicables a la optimización de procesos industriales, sino también a productos y lograr mayor valor agregado a partir de funcionalidad o servicio.

Las principales características de las soluciones tecnológicas que componen la I4.0, según Smit (2016) son:

- Interoperabilidad: CPS (transportes, estaciones de trabajo, y productos) permiten a las personas y fábricas inteligentes conectarse y comunicarse entre ellos.
- Virtualización: una copia virtual de una fábrica inteligente se crea vinculando datos de sensores con el modelo de planta virtual y modelos de simulación.
- Descentralización: la habilidad de los CPS para tomar decisiones propias y producir localmente gracias a tecnologías como impresión 3D.
- Capacidad en tiempo real: la capacidad de tomar y analizar datos, y proveer los hallazgos inmediatamente.
- Orientación al servicio
- Modularidad: adaptación flexible de fábricas inteligentes a cambios de requerimientos reemplazando o expandiendo módulos individuales.

Para redondear la descripción de los elementos de la tecnología computacional que componen el paradigma de I4.0, Smit (2016) se refiere al potencial disruptivo para la transformación de la producción que encapsula el modelo I4.0, al considerar que por primera vez es posible vincular sistemas que tradicionalmente estuvieron separados dando el ejemplo del uso de tecnología RFID o mini transponders. Esto significa que cada producto posee información digital embebida en él, y puede ser compartida al moverse a través de la cadena de valor, comunicándose independientemente de la interferencia humana. Así la información generada puede ser analizada con procesos de big data y computación en la nube. De esta manera es posible permitir resolver trazabilidad, detectar y resolver temas específicos de los procesos como desgaste de la herramienta, uso de componentes, entre otros, en el piso de planta. Teniendo en cuenta que todo es realizado automáticamente, los dispositivos inteligentes son capaces de gestionar las operaciones de manufactura y optimizarlas en forma autónoma, ajustando sus propios parámetros a medida que censan propiedades de un producto.

### **1.9 Metodologías Ágiles**

El último elemento que se introducirá para iniciar el tratamiento del tema está referido al nuevo paradigma de gestión de proyectos y puesta en el mercado de productos.

La incertidumbre en el entorno de negocios, acelerado por el vertiginoso cambio tecnológico, en el marco de la evolución del paradigma hacia el modelo I5.0 más sostenible y centrado en el ser humano, también ha generado la necesidad de un nuevo estilo de gestión de proyectos. Los enfoques tradicionales basados en planes ya no son efectivos y deben actualizarse con prácticas más centradas en las personas y basadas en el valor.

Por lo tanto, en los últimos tiempos se ha generado una evolución del ámbito de la producción hacia metodologías más dinámicas y flexibles con mayor orientación al cliente, estas metodologías son las denominadas Ágiles (Cooper and Sommer, 2018, Ullman, 2019). El concepto que subyace detrás de estas metodologías es facilitar la adaptación del proyecto a condiciones de borde que cambian permanentemente y poder interactuar con el cliente para obtener feedback con la mayor frecuencia posible, y lograr la cocreación de la nueva

solución. De esta manera, se pretende entregar un producto lo más ajustado posible a los requerimientos de la demanda. Por otro lado, las metodologías ágiles a partir de explotar los beneficios de la generación de soluciones iterativas e incrementales, típicos del desarrollo ágil de software, permite que el cliente o el adoptante de la solución se involucre en el proceso de desarrollo en una instancia temprana, y se transforme en cocreador de la nueva solución.

### **1.10 La economía conectada**

Este concepto desarrollado por Andrei Vazhnov (2015), hace referencia a las plataformas informáticas y su integración que permite un efecto de ubicuidad y alcance extraordinario permitiendo modelos de negocio y trabajo disruptivos. El autor cita especialmente los casos de Uber y Airbnb. Una plataforma es un entorno donde se ejecuta una aplicación, y a partir de la conectividad en red esta definición se ha extendido a un espacio donde distintos usuarios pueden interactuar entre ellos o con objetos físicos. Esto da lugar a lo que se denominó como CPS.

La integración y alcance de las plataformas se genera al estar conectadas a través de APIs. Una API, acrónimo de *Application Programming Interface*, es el mecanismo que permite integrar dispositivos y plataformas. Es algo que facilita por ejemplo que aplicaciones que utilizan georreferenciación puedan acceder a información de Google Maps.

Este fenómeno de mundo líquido, como lo llama Vazhnov (2015) a partir de la posibilidad que genera internet y la movilidad, posibilita reconfigurar cadenas globales de valor, e integrar distintas plataformas para facilitar la gestión de las operaciones. Creemos que es un elemento emergente de la evolución de las TICs y tiene fuerte implicancia en el desarrollo del modelo I4.0.

Además, este fenómeno puede considerarse también como un emergente del paradigma de innovación abierta del tipo *Outbound* según Di Minin et al (2016), donde presenta casos de empresas que integran sus productos para conformar plataformas con un mayor alcance y completar funcionalidad.

### **1.11 Innovación abierta.**

El término innovación abierta se ha hecho popular a partir de los trabajos del Prof. Henry Chesbrough (2003). Aunque también podemos citar trabajos previos de Von Hippel (1988, 2005), un investigador del MIT que sin mencionar explícitamente el término innovación abierta, ha desarrollado el concepto de la innovación desde distintas fuentes en su trabajo *Sources of Innovation* (1988). Más tarde profundizó la importancia de las comunidades de innovación y su interacción en el trabajo *Democratizing innovation* (2005).

La innovación abierta es un modelo de innovación que no posee una definición exacta, pero podemos afirmar que se trata de innovar a partir de inputs del mercado, compartir estándares de fabricación, interfaces y modelos de gestión con otras empresas (incluso competidoras en el mismo sector) puede permitir una mayor velocidad para la innovación por la reducción de costos y riesgos asociados a los procesos de I+D+i. Como existen economías de plataforma, tal como mencionamos en el apartado anterior, cuanto mayor sea el número de participantes mejor será la funcionalidad de la plataforma. Basco et al (2018) cita en su artículo el ejemplo de Nova Paint Club en la empresa Sinteplast en Argentina.

Un emergente de la innovación abierta es el surgimiento de opciones de software y hardware libre. La modalidad “*open source*”, genera una enorme oportunidad para la difusión de la tecnología y como titula Von Hippel (2005), haciendo posible la “Democratización” de la innovación.

El motivo por el cual se introduce este concepto, está relacionado con la complejidad de las herramientas tecnológicas, su integración y la necesidad de interacción entre actores de distinta naturaleza durante el proceso de adopción de la herramienta en la empresa industrial, es decir la concreción de la innovación. En este sentido podemos citar la posibilidad de integrar soluciones de software o hardware libre con herramientas corporativas. Otro caso de aplicación de innovación abierta es la posibilidad que brindan las plataformas *open source*, como el caso del software de gestión ODOO (2022). Esta es una plataforma de clase mundial que esta accesible a empresas de distintas características y segmentos, y facilita la adopción de una plataforma que permita integrar todos los procesos de la empresa sin incurrir en una gran inversión. Un último caso podría ser el de una gran empresa tecnológica que se



asocia a un equipo de desarrollo de una universidad para adaptar una solución tecnológica global a las necesidades de una empresa local.

Mónica Casalet (2018) en su trabajo sobre la digitalización industrial indica que el trabajo colaborativo y multidisciplinario es una condición del proceso para lograr diseños efectivos y viables, así como también la necesidad de generar normas y protocolos en las interfaces entre componentes.

Finalmente, la Innovación Abierta se nutre de un ecosistema de innovación donde es muy importante la especialización y la conectividad. Di Minin et al (2016), expresa que el lugar de la innovación ya no está en las grandes empresas individuales, sino en las redes de innovación, que involucran distintos socios: universidades, laboratorios, Startups, PYME, multinacionales y gobiernos. Las relaciones entre estos jugadores determinan en gran medida el rendimiento general de un ecosistema de innovación. La innovación abierta es esencial para el correcto funcionamiento de estos ecosistemas, ya que se basa en el intercambio de ideas y la explotación de recursos dentro y fuera de las organizaciones.

### **1.12 Alcance de la tesis**

Para iniciar la discusión del tema que se pretende abordar, se pone en consideración la definición de modelo operativo de negocio y modelo de negocio según Iansity & Lakani (2020). Los autores definen que el valor de una empresa está determinado por estos dos conceptos. El modelo de negocio de la empresa, definido como la forma en que la empresa promete crear y capturar valor. Mientras que el modelo operativo de la empresa, es definido como la forma en que la empresa entrega el valor a sus clientes.

Tomando como referencia el trabajo de Walas Mateo & Redchuk (2021), se puede observar que existe suficiente evidencia sobre el uso y beneficios de la analítica de datos en el entorno productivo, en este trabajo se pretende estudiar y analizar las oportunidades y dificultades que surgen del uso de la Inteligencia Artificial y el Aprendizaje Automático en el entorno industrial para mejorar los procesos industriales.

Por otro lado, Da Silva et al. (2019) observan que para implementar el concepto de I4.0, además del conocimiento técnico, se deben evaluar una diversidad de

otros temas, como (i) ¿Cuáles son las ventajas y desafíos que presenta este concepto? (ii) ¿Cuáles son los recursos que las empresas necesitan disponer? (iii) ¿Cuáles son las barreras inherentes al proceso de adopción? Comprender estos problemas es fundamental para una mejor dirección con respecto a la implementación y la evolución de las soluciones vinculadas a la estrategia I4.0. Estas son algunas de las preguntas que se han considerado como parte del problema de investigación que se plantea y que se pretende responder en esta tesis.

Otra observación que es objeto de este trabajo es lo que establece Muhuri et al. (2019), referente a que la digitalización de productos y servicios se ha convertido en una necesidad para un ecosistema industrial sólido. Sin embargo, estos requisitos y tecnologías avanzadas han hecho que los sistemas sean más complejos y han llevado a muchos otros desafíos como ciberseguridad, confiabilidad, integridad, etc. Estos son algunos de los principales cuellos de botella que deben superarse para el diseño e implementación exitosos del modelo I4.0.

En el texto de Iansiti & Lakani (2020) se conceptualiza a la Fábrica de Inteligencia Artificial (IA) como el núcleo de la empresa moderna, donde se industrializa la recopilación de datos, el análisis y la toma de decisiones. La fábrica de IA es el motor de decisiones escalable que impulsa el modelo operativo digital, donde se crea valor, de la empresa del siglo XXI. Las decisiones gerenciales están cada vez más integradas en el software, que digitaliza muchos procesos que tradicionalmente han sido llevados a cabo por empleados. Los modelos operativos digitales pueden tomar varias formas, las fábricas de IA están en el centro del modelo, guiando los procesos más críticos y las decisiones operativas, mientras que los humanos se mueven al límite, fuera del camino crítico de la entrega de valor. A partir de los conceptos aportados por estos autores se deben considerar dos puntos en este trabajo. El primero es transformar el entorno industrial en un entorno de fábrica de IA, y el segundo es el nuevo rol del operador industrial, o del ingeniero industrial.

Este trabajo tiene como objetivo tomar en consideración los problemas de los párrafos anteriores, en el marco de la adopción de soluciones AI/ML. Un tema clave a explorar es cómo los operadores de procesos o ingenieros industriales

pueden hacer frente al desafío que significa la disrupción que se produce en el escenario industrial al adoptar modelos de análisis de datos.

Por lo tanto, el alcance de esta tesis está focalizado en metodologías que faciliten la gestión del cambio en la organización, para la adopción de soluciones de Inteligencia Artificial de forma efectiva en término de uso de recursos, y exitosa en cuanto al logro de los resultados planificados al inicio del proceso de implementación de la nueva solución.

El alcance comprende investigar como las empresas industriales tradicionales pueden evolucionar hacia el nuevo paradigma I5.0 y su complementación con el I4.0 a partir de la utilización de las metodologías citadas en el párrafo anterior.

Se analizarán metodologías que logren el modelo de Inteligencia Artificial centrado en el usuario. En este sentido se profundizará como hacer realidad la incorporación de herramientas digitales que tradicionalmente requieren recursos con conocimiento de programación de software, herramientas matemáticas y estadísticas, en un entorno donde el ingeniero de procesos y operador de planta no siempre cuentan con estas competencias. Por otro lado, debemos considerar las cuestiones de borde de la operación industrial en cuanto a factores que intervienen, es decir características del entorno, de los procesos, personas, materiales, máquinas, entre otros.

Un punto central de la tesis será indagar sobre mecanismos para lograr integrar los conocimientos del proceso, que posee el operador en la planta con la solución analítica a desplegar. De esta forma lograr el empoderamiento de las personas en la planta, y maximizar la optimización de los procesos operativos consumiendo la menor cantidad de recursos en el proceso de adopción, y lograr impacto significativo en el corto plazo.

Además, debe considerarse las oportunidades para generar nuevos modelos de negocio centrados en el usuario y en el cliente. Este punto que se enuncia en el trabajo de Walas Mateo & Redchuk (2020), será profundizado y analizado con mayor detalle en la presente tesis.

Por último, se incluyen también cuestiones relacionadas con innovación abierta, y el ecosistema de innovación para poder integrar soluciones de distintos orígenes, facilitar el acceso a soluciones tecnológicas que permitan desarrollar

la plataforma analítica adecuada para cada proceso industrial con los mejores resultados operativos en términos de KPI.

### **1.13 Hipótesis de la tesis**

Habiendo planteado el alcance del trabajo es posible avanzar en el planteo de la hipótesis sobre la que se trabajará en la presente tesis.

En primer término, se aparece la cuestión asociada a la necesidad de democratización de la aplicación de modelos analíticos en las empresas industriales a través de nuevos modelos operativos y de negocio, donde el usuario y el cliente deben ser el foco de esos modelos.

Luego se debe considerar la velocidad de adopción de los nuevos modelos en el marco de la estrategia I4.0/I5.0 y la necesidad de alcanzar el mejor resultado a partir de la inversión en recursos, que por menor que sea, debe traer un retorno a la inversión (o ROI según sus siglas en inglés) positivo, en plazos cortos, y el mayor posible.

Por lo tanto, en esta tesis se buscará desarrollar conocimiento para responder las siguientes preguntas:

¿Es posible adoptar los nuevos modelos de negocio en el menor tiempo posible con el mayor retorno de la inversión?

¿Cómo preparar a las personas involucradas en los procesos operativos para poder operar los nuevos modelos?

¿Cómo es posible saber de manera temprana si el proceso de adopción del nuevo modelo tendrá impacto cuando esté completamente desplegado?

¿Es posible desarrollar nuevas startups tecnológicas que ofrezcan soluciones de IA/ML que faciliten la aplicación de analítica prescriptiva en los procesos industriales?

¿Cómo se integra la arquitectura IIoT con soluciones IA/ML para generar procesos inteligentes a partir del uso de la analítica prescriptiva?

¿Es posible lograr empoderar a las personas en los procesos industriales y lograr ámbitos productivos ambientalmente más amigables, en el marco del paradigma I5.0?

Para validar la investigación objeto de esta tesis, se trabajará sobre el modelo de negocios, y la solución de inteligencia artificial y aprendizaje automático para

procesos industriales que facilita el paradigma de las Plataformas Low-Code (LCP por sus siglas en inglés). Además, se considerará la utilización de metodologías ágiles, en particular la metodología Lean Startup (Ries, 2011). Estos elementos generan interés para esta tesis por varios aspectos, más allá de la posibilidad de proponer un modelo de negocio innovador permitiría democratizar el uso de soluciones de inteligencia artificial en procesos industriales.

El aspecto más destacable es el hecho de que la propuesta de valor que impulsa el modelo de negocios está centrada en una LCP, es que permite simplificar la adopción de modelos de datos en la industria. De esta manera propone simplificar la optimización de procesos industriales a partir de inteligencia artificial y aprendizaje automático.

Otras características interesantes a desarrollar sobre el modelo de negocio y la mirada del paradigma I4.0 y su evolución al modelo I5.0, serán la integración de esta plataforma con otras soluciones, el modelo de comercialización de software como servicio (SaaS), y la consideración de los operadores de los procesos para ser empoderados por las herramientas de IA.

# **CAPÍTULO 2 – IIoT, Inteligencia Artificial, Aprendizaje Automático, y Datos en el entorno Industrial**

## **2.1 Introducción.**

En este capítulo se desarrollan los conceptos asociados a la generación de datos desde los procesos industriales, y su transformación en información para que las empresas industriales evolucionen hacia el modelo I4.0 para alcanzar el I5.0.

Se presentan conceptos clave y un análisis del estado del arte sobre mejores prácticas para integrar datos desde las operaciones industriales, y utilizarlos para generar información de valor agregado para optimizar los procesos industriales. Se tratan temas de estándares sobre arquitectura de Tecnología de Operaciones (OT) y Tecnología Informática (IT), se incluyen conceptos de Internet Industrial de las Cosas (IIoT), Inteligencia Artificial y Aprendizaje Automático (AI/ML).

Se desarrolla el marco conceptual para analizar a la AI/ML como motor de optimización de procesos, la integración con IIoT y el potencial para producir datos para alimentar los modelos de AI/ML estrictamente en el ámbito industrial.

Al final del capítulo se presenta un análisis de oportunidades y debilidades que presentan estas soluciones para la optimizar de procesos en el ámbito industrial según las condiciones de borde establecidas para los nuevos modelos de producción.

## **2.2 Generación de datos del proceso industrial, arquitectura integrada**

Para iniciar este tema, consideremos el artículo de He & Xu (2014) donde destacan la necesidad de considerar el enfoque de sistemas al abordar la investigación en la integración de la información industrial. El texto presenta el modelado y la integración de flujos de información para la vinculación de la información empresarial a través de la arquitectura que propone IIoT.

El tema de la recopilación e integración de información ha sido abordado por organismos de normalización autorizados como la Sociedad Internacional de

Automatización (ISA) (2022) y la Comisión Electrotécnica Internacional (IEC) (2022). Como ejemplo, el estándar multicapa IEC 62264 basado en las especificaciones ISA-95 (2010) define un marco de intercambio de modelos de información que permite la integración de aplicaciones que se ejecutan en áreas de gestión, y operaciones. Las empresas que cumplen con este estándar pueden definir interfaces entre el control y las funciones de gestión, lo que les permite tomar decisiones informadas sobre los datos para intercambiar de forma que los costos y los riesgos se mantengan bajos en caso de errores de implementación.

La figura 1 muestra la arquitectura de niveles que propone el estándar ANSI/ISA-95. Esta norma internacional ha sido generada para abordar los problemas que surgen durante el desarrollo de interfaces automatizadas en el ámbito de los sistemas de gestión de la empresa y los sistemas de control. Este estándar proporciona una guía para la integración vertical de la información de la firma.

El estándar ISA 95 define un modelo de jerarquía funcional para categorizar las funciones de las empresas industriales. Este modelo de 5 capas es conocido como la pirámide de automatización.

El nivel 0 es donde los procesos productivos son realizados. En ese nivel el marco operacional esta medido en milisegundos (Åkerman, 2018). En este nivel se encuentran los sensores (presión, temperatura, caudal, etc.), y todos los dispositivos de campo (actuadores, servo motores, etc.).

El nivel 1 representa la primera capa lógica, donde los datos recibidos desde el nivel anterior son procesados. Los procesos operativos en este nivel se basan en mecanismos de retroalimentación constantes. En esta instancia aparecen elementos de control como Controladores Lógicos Programables (PLC), variadores de velocidad, entre otros. El marco temporal esta dado en segundos.

El nivel 2 representa la capa de automatización, donde se generan mecanismos de control y automatización. En esta instancia aparecen las Interfaces Hombre Máquina (HMI), sistemas de Supervisión Control y Adquisición de Datos (SCADA). Estos sistemas se comunican con las capas inferiores como los PLC a través de protocolos, estándares de comunicación, como *MODBUS*. El marco temporal en este nivel esta dado en minutos.

El siguiente nivel, el 3, es la capa donde ocurre la contextualización con el producto que es fabricado. En esta capa se definen y mantienen las recetas o lista de Materiales (BOM). El sistema que trabaja en esta instancia es el Sistema de Ejecución de Manufactura (MES), sobre esta herramienta es posible que operadores ingresen datos. El marco temporal se da en horas hasta días.

El último nivel, el 4, representa la instancia de gestión, planificación, e inteligencia de operaciones y negocio. El elemento clave es el Sistema de Planificación de Recursos de la Empresa (ERP). Acá también podemos encontrar soluciones de AI en la nube. El marco de tiempo se da en semanas hasta meses.

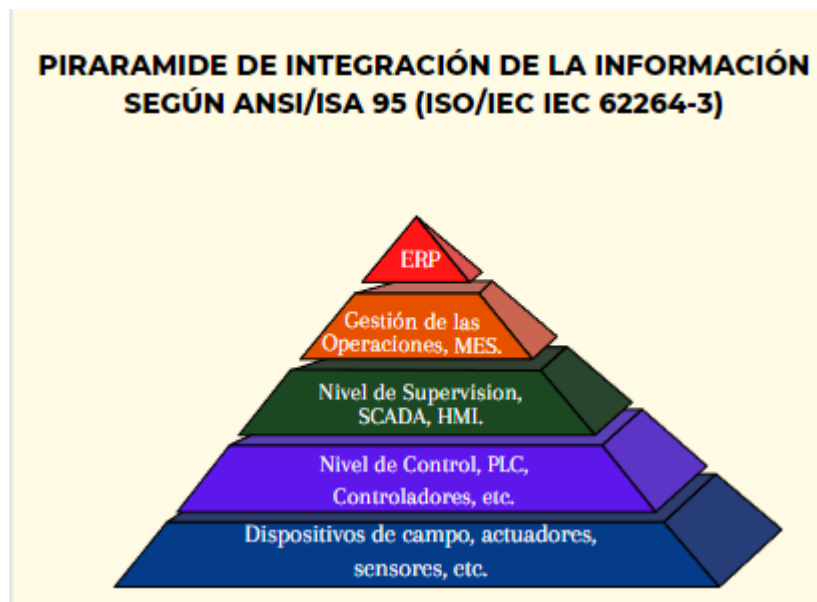


Fig. 1. Modelo de integración vertical de la Información que propone el estándar ANSI/ISA 95. Fuente: Elaboración propia.

Para concluir este punto debemos observar que, aunque el modelo ISA 95 y la pirámide de la automatización son aun pertinentes para respaldar las tecnologías de producción inteligente e IIoT, parecería necesario analizar la extensión de este modelo a partir de los desafíos que presentan las nuevas variantes tecnológicas. Este ítem se adelanta como una de las futuras líneas de investigación.



## **2.3 Elementos de IIoT**

Seetharaman et al. (2019) consideran que la plataforma de IIoT comprende cuatro capacidades fundamentales: conectividad, big data, analítica avanzada y desarrollo de aplicaciones. IIoT tiene el potencial de proporcionar un alto nivel de sinergias entre hombre, máquina, material y método. Según el autor, a los proveedores de servicios les interesa colaborar y proporcionar una solución universal para conservar los sistemas heredados a fin de minimizar la inversión y reducir la amenaza a la seguridad, lo que podría impulsar la adopción de IIoT al tiempo que garantiza que los fabricantes puedan aprovechar esta nueva tecnología de manera eficiente.

Sobre los elementos de IIoT, Chandler et al (2022) identifica seis componentes, que se muestran en la figura 2. Se describen a continuación:

### **2.3.1 Identificación**

Este componente se refiere a la posibilidad de reconocer cada dispositivo correctamente en el ámbito de la red en forma correcta, es decir asignar una ID de dispositivo a una dirección IP específica.

### **2.3.2 Sensado**

La infraestructura de IIoT se nutre de datos del ambiente de operaciones para transmitirlos a la base de datos local, o a la nube para su procesamiento. En este componente se identifican sensores, procesadores, y dispositivos que puedan aportar datos de la operación.

### **2.3.3 Comunicación**

En general, la mayoría de los artefactos de IIoT se conectan a través de la red. En el ámbito industrial, y esta es una de las particularidades más notables de la IIoT, es que la comunicación debe soportar connotaciones ruidosas y con pérdida de calidad. Algunos de las tecnologías utilizados por IIoT son, WiFi, Bluetooth, NFC, RFID, Lora, e IEEE entre otros.

### 2.3.4 Proceso Computacional

El poder de cómputo de los dispositivos de hardware es una variable esencial en IIoT. Los componentes de computación como microprocesadores, microcontroladores representan el cerebro de la arquitectura.

### 2.3.5 Servicios

Este es el elemento de IIoT que genera insumos específicos para el usuario final (por ejemplo, monitoreo de dispositivos o mantenimiento predictivo).

### 2.3.6 Semántica

La operación semántica en IIoT funciona con información abstracta útil que surge de manera inteligente desde diferentes artefactos. Este ítem se refiere a los distintos protocolos que permiten estandarizar la comunicación. Algunos de estos son: (RDF), Wide Web Consortium (W3C), Efficient XML Interchange (EXI) y Web Ontology Language (OWL).

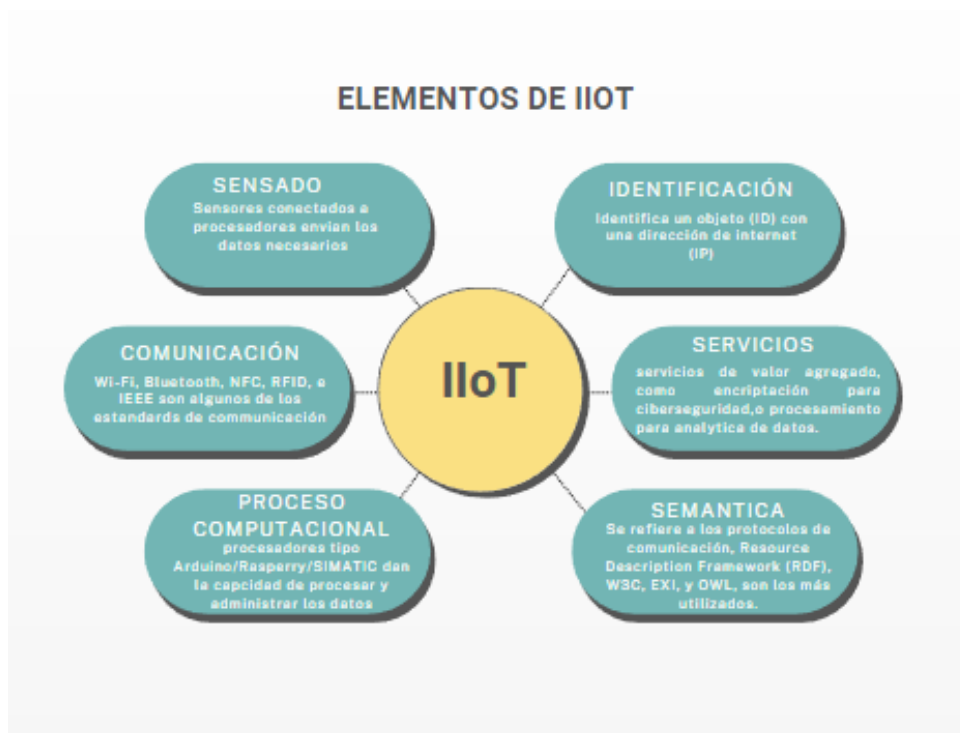


Fig. 2. Componentes de IIoT según Chander et al (2022).

## **2.4 Arquitectura de IIoT. Integración de IT y OT a través de IIoT**

La OT consiste en sistemas que monitorean y controlan procesos físicos que administran procesos automatizados de fabricación, y las aplicaciones asociadas suelen ser críticas para la seguridad, en tiempo real, incorporando propiedades adicionales no funcionales, como latencia limitada, confiabilidad y cumplimiento de estándares de seguridad y protección específicos de la industria (Garbugli et al., 2021; Arestova et al, 2021).

Hasta ahora, las IT, como computación *Cloud/Edge*, arquitecturas orientadas a servicios (SOA) y virtualización, han sido explotados en aplicaciones industriales solo de forma limitada, es decir, solo en contextos donde no se necesitaban requisitos muy estrictos. Sin embargo, cada vez es más evidente que I5.0 tendrá un impacto muy significativo solo con una convergencia total de OT/IT que impulsará para la profunda explotación conjunta de las tecnologías informáticas y de comunicación más recientes.

El artículo de Patera et al (2022) desarrolla el marco conceptual sobre la infraestructura IT y OT para facilitar el modelo I5.0. La convergencia de OT/IT es fundamental para la integración de datos, y sobre todo para avanzar en soluciones de AI en el proceso de toma de decisiones industriales, proporcionando la base para una planta con capacidad cognitiva. El artículo incluye un caso real que satisface las necesidades específicas de IT y OT, logrando una transferencia rápida y homogénea de grandes volúmenes de datos hacia la capa de IT.

Lara et al. (2020) considera que con el auge de tendencias como IIoT y fabricación en la nube que buscan la convergencia de herramientas de IT en redes de OT, el análisis de IT y OT es muy buscado en las industrias actuales que buscan soluciones en tiempo real. análisis de los datos. Para analizar los datos en el dominio IT y OT es necesario utilizar modelos, que no solo se centren en describir ambos dominios, sino que también puedan mostrar la relación entre ellos. En este artículo se presenta una técnica que utiliza los datos operativos, producidos en una organización a partir de soluciones IIoT, para modelar OT, con el fin de aplicar métodos de análisis.

## **2.5 IIoT como facilitador de la AI/ML**

En esta sección se desarrollan conceptos, y un análisis del estado del arte sobre IIoT como solución que habilita y genera oportunidades para la adopción de soluciones de AI tales como ML.

Para comenzar a analizar esta arista, se puede citar el trabajo de Walas Mateo & Redchuk (2021), donde se realizó una investigación a partir de un análisis bibliométrico sobre el impacto de IIoT para el éxito de AI/ML como motor de optimización de procesos en la I4.0. El trabajo valida la hipótesis, aunque resalta la complejidad intrínseca que presenta este tipo de soluciones, observa la novedad del tema, y por último que el tema es dominado por el ámbito científico académico, pero existe una limitada aplicación en la industria.

En el marco de los sistemas de producción inteligente, el ecosistema de manufactura está compuesto por una amplia variedad de dispositivos que recolectan datos de los distintos procesos industriales. Yalcinkaya et al. (2021) afirma que IIoT es una nueva generación de tecnología que se enriquece con la existencia de soluciones que toman datos a nivel piso de planta (sensores, actuadores, etc.) con altos grados de precisión. Por lo tanto, la visibilidad de las operaciones ha avanzado a nuevos niveles que facilitan la adquisición de una vasta cantidad de datos y retroalimentación prácticamente instantánea. De esta manera es posible adoptar algoritmos de AI que facilitan la productividad y eficiencia en los procesos.

Un trabajo de Silveira et al. (2020) estudia el modelo I4.0 en la industria de los semiconductores, donde la alta confiabilidad y los bajos costos operativos son críticos para el éxito de un negocio. En este contexto, ese trabajo propone un piloto I4.0 como una recopilación de las lecciones aprendidas durante el desarrollo de un diseño de referencia aplicado a una empresa de pruebas y empaquetado de semiconductores. Se exploran los requisitos de las salas limpias y la información relacionada con los sensores y las placas de adquisición de datos, además de los detalles de rendimiento y las configuraciones relacionadas con las herramientas de visualización y las notificaciones de advertencia de las herramientas de AI.

Yang et al (2020) observa que la fabricación inteligente es un nuevo paradigma que permite que la fabricación entre en su cuarta revolución mediante la

explotación de sensores, comunicaciones y computación de última generación como el IIoT. Mediante el uso de computación de alto rendimiento y modelado avanzado, SM tiene como objetivo mejorar la flexibilidad y adaptabilidad de la fabricación. Los autores abordan esta metodología mediante la revisión del uso combinado de modelos híbridos basados en datos y basados en el conocimiento, y analiza cómo dichas técnicas encajan perfectamente en la plataforma de fabricación inteligente. Además, se brinda una discusión sobre los nuevos paradigmas de modelos híbridos habilitados por la plataforma de fabricación inteligente.

En el artículo de Vatter et al. (2019) se afirma que IIoT, big data, análisis de datos, y computación en la nube están cambiando la producción hacia la próxima generación de la industria. Para abordar estos desafíos, la fabricación inteligente en combinación con el análisis de datos juega un papel importante. En este sentido, la integración de análisis prescriptivos en la fabricación puede ayudar a la industria a aumentar la productividad. Este documento destaca los requisitos para un control de producción basado en análisis prescriptivo, llamado automatización prescriptiva, y finalmente señala el campo de actividades en este tema.

Finalmente, Khakifirooz et al (2018) se refieren al análisis de big data como impulsor de la inteligencia de fabricación efectiva para la gestión del rendimiento en la fabricación de semiconductores, que es uno de los procesos de fabricación más complejos, como observan los autores, debido a los procesos de producción estrictamente restringidos, flujos de procesos reentrantes, equipos sofisticados, demandas volátiles y una mezcla de productos complicada. De hecho, la creciente adopción de sensores multimodo, equipos inteligentes, y robótica ha permitido la evolución de IIoT y el análisis de big data para la fabricación de semiconductores. El estudio desarrolla un marco basado en la inferencia bayesiana y el muestreo de Gibbs para investigar los intrincados datos de fabricación de semiconductores para la detección de fallas y potenciar la fabricación inteligente. El enfoque propuesto fue validado a través de un estudio empírico y simulación. Los resultados han demostrado la viabilidad práctica del planteo realizado en este trabajo.

## **2.6 La Inteligencia Artificial en los procesos industriales**

Existen diferentes trabajos en temas de Inteligencia Artificial para la búsqueda de mejores procesos operativos los cuales han motivado la investigación que se desarrolla en este trabajo. Uno de ellos es el artículo “Un sistema de soporte de decisiones difusas para gestionar actividades de mantenimiento de componentes críticos en sistemas de fabricación” de İhsan Erozan (2019), otro que despierta interés es “Aplicaciones de aprendizaje automático en líneas de producción: una revisión sistemática de la literatura” de Ziqiu Kang et al. (2020). Estos documentos brindan excelentes conocimientos y conceptos sobre AI/ML para optimizar las operaciones industriales. Al igual que otros trabajos, estos artículos se centran en la metodología analítica y los beneficios de aplicar AI/ML en procesos industriales. En este punto, no hay dudas sobre el valor agregado y la viabilidad del análisis de datos en la fabricación. Lo que se pretende estudiar en esta investigación es el estado del arte de la ciencia de datos en el entorno industrial y sobre todo cómo democratizar el uso de AI/ML y llegar a un despliegue más masivo para buscar la excelencia en los procesos productivos.

Estudios recientes sobre producción inteligente con algoritmos ML cubren áreas en el ámbito industrial que incluyen planificación de producción, consumo total de energía, programación de máquinas, diseño de productos y mecanizado sostenible (Javaid et al., 2020). La inclusión de tecnologías emergentes como IoT, inteligencia artificial, análisis de datos, servicios de entrega digital está influyendo en las prácticas de producción inteligente en la era de la I4.0 (Jamwal et al., 2021; Machado et al., 2020). Algunos estudios han informado que el uso de estas tecnologías avanzadas en la fabricación sostenible da como resultado la minimización del consumo total de energía, la reducción de los insumos de mano de obra y una mejor predicción del mantenimiento basada en las condiciones (Khan et al., 2017).

Por otro lado, algunos autores (Jamwal et al., 2021; Kumar et al., 2018) consideran que uno de los principales desafíos es la generación de una gran cantidad de datos. Esto se justifica por el hecho de que los datos generados serán útiles para la toma de decisiones, pero se deben organizar, y analizar mediante el uso de herramientas de modelado de datos.

Las industrias actualmente están aplicando inteligencia artificial y aprendizaje automático para mejorar la eficiencia, la seguridad de los empleados y mejorar

la calidad del producto. En las empresas manufactureras, el mantenimiento continuo de las líneas de producción y la maquinaria resulta en gastos importantes, que también tienen un impacto importante en el resultado final de cualquier operación de producción dependiente de activos (Sharp et al., 2018).

Según Hernández Orallo et al. (2004), ML o aprendizaje automático es el área de la inteligencia artificial que se ocupa de desarrollar algoritmos (y programas) capaces de aprender, y constituye, junto con la estadística, el corazón del análisis inteligente de los datos. Los principios seguidos en el aprendizaje automático son similares a los aplicados en la minería de datos: la máquina aprende un modelo a partir de ejemplos y lo usa para resolver el problema.

La aplicación de técnicas de ML en la fabricación ha ganado popularidad en las últimas dos décadas (Sharma et al., 2020). En la actualidad, considerando el ámbito industrial, las herramientas de aprendizaje automático se utilizan en diversas áreas, p. Ej. resolución de problemas, control y optimización (Syafrudin et al., 2018). El alcance de las técnicas de ML en la producción, según distintos requerimientos del sector, se muestra en la tabla 2.

<b>Requerimientos de Fabricación</b>	<b>Capacidad de ML para alcanzar requisitos de producción</b>
Capacidad de manejar grandes volúmenes de datos y problemas complejos.	Algoritmos de ML son capaces de manejar grandes volúmenes de datos con problemas complejos.
Capacidad para adaptarse a nuevos escenarios por cambios tecnológicos a costos y esfuerzos razonables.	ML como parte de Inteligencia Artificial aprende y se adapta a cambios en el ambiente productivo que genera la adopción de la nueva tecnología.
Capacidad de minimizar la naturaleza compleja de los resultados.	Las técnicas de ML pueden manejar patrones de grandes volúmenes de datos y pueden anticiparse a futuros comportamientos de un sistema.
Capacidad para trabajar con datos disponibles de maquinas o procesos productivos.	Las técnicas de ML están diseñadas de tal manera que pueden generar conocimiento de datos existentes cuando son procesados. Estos datos procesados es usada para predicciones de comportamiento, ej. Mantenimiento.
Capacidad de identificar relaciones entre e intra procesos.	Las técnicas de ML pueden contribuir a generar nueva información y conocimiento identificando patrones a partir de datos existentes.

Tabla 2. Posibilidad de generar información para la gestión de la producción de soluciones de ML según requerimientos de la producción específicos.

Las técnicas de ML son parte de la inteligencia artificial, y pueden aprender y adaptarse a nuevos cambios en los sistemas (Loyer et al., 2016). Priore et al., (2001) desarrollan un artículo donde argumentan porqué las técnicas de ML son

necesarias en el sector manufacturero. Según este artículo aprender del entorno, y adaptarse automáticamente de acuerdo con los requerimientos que marca la demanda, es la principal fortaleza de las técnicas de aprendizaje automático.

Cuando nos referimos a la integración de la información y su arquitectura para contar con datos para nutrir los algoritmos de ML, podemos considerar el estándar ISA 95 visto anteriormente. Tal como se observó cuando se trató este estándar, en los niveles inferiores ocurre la captura de la información y las actividades de control, y a medida que llegamos a los niveles superiores la complejidad aumenta. En los dos niveles superiores es donde las plataformas de gestión y planificación comparten datos y se comunican entre ellas. Pedone & Mezgar (2020) estudiaron sistemas altamente heterogéneos en I4.0 desde la perspectiva de la adaptación con el modelo de la nube, incluyendo sistemas IIoT y CPS. En el trabajo que presentan justifican que la interoperabilidad y la portabilidad de datos son los desafíos más importantes para adoptar nuevas tecnologías en el complejo ecosistema I4.0.

En el mismo texto los autores, destacan que es en los dos niveles superiores donde los sistemas productivos se benefician con la adopción de computación en la nube, big data, AI, y ML. La figura 3 muestra donde se genera el espacio para adoptar ML en la pirámide de automatización.



Fig. 3. Donde se presentan las oportunidades de adopción de soluciones de ML en los procesos industriales según el estándar ISA 95.



Witten et al. (2017), presenta el ciclo de vida de referencia de proyectos de Data Science, aplicable a ML en la industria. El Cross Industry Standard Process for Data Mining (CRISP-DM) es un modelo de proceso que sirve como base para un desarrollo de ciencia de datos. El mismo tiene seis fases secuenciales:

- 1- Entendimiento del negocio – ¿Qué necesita el negocio?
- 2- Comprensión de datos: ¿qué datos tenemos/necesitamos? ¿Está limpio?
- 3- Preparación de datos: ¿cómo organizamos los datos para el modelado?
- 4- Modelado – ¿Qué técnicas de modelado debemos aplicar?
- 5- Evaluación: ¿Qué modelo cumple mejor con los objetivos comerciales?
- 6- Implementación: ¿cómo acceden las partes interesadas a los resultados?

Publicado en 1999 para estandarizar los procesos de minería de datos en todas las industrias, desde entonces se ha convertido en la metodología más común para proyectos de minería de datos, análisis y ciencia de datos.

Según Witten et al. (2017), la metodología de adopción sugerida para un proyecto de ML, u otro de ciencia de datos, debería combinar una implementación flexible de CRISP-DM con enfoques generales de gestión de proyectos ágiles basados en equipos para obtener los mejores resultados. La figura 4 ilustra el ciclo de vida del CRISP-DM.

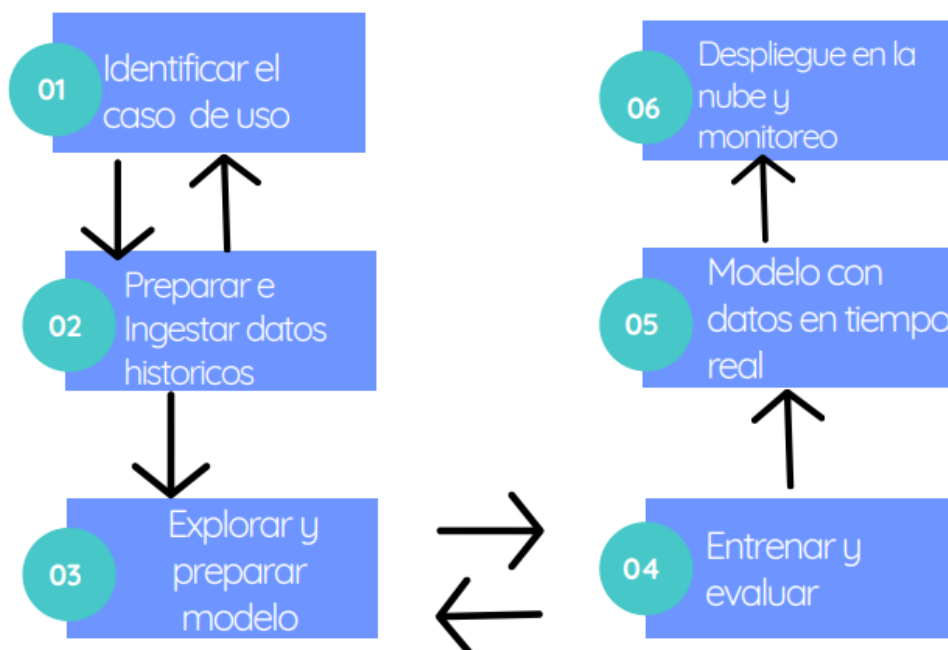


Fig. 4- Ciclo de vida de un proyecto de ML según el modelo CRISP- DM.

Por último, sobre la aplicación de AI/ML en los procesos industriales, en términos de Brun et al. (2019) este tipo de soluciones también representa un upgrading del proceso, es decir, permite llevar a los procesos industriales a niveles superiores para generar cadenas de valor globales más competitivas. Bajo este punto de vista, se deben considerar algunas otras cosas en este documento, como el tiempo y los recursos necesarios para implementar y capturar el valor de AI/ML en el taller, los costos y el ROI, la calidad y cantidad de datos necesarios para alimentar los modelos analíticos, entre otros elementos.

## **2.7 Antecedentes de aplicación de AI/ML en la industria**

Esta sección presenta un análisis del estado del arte en la adopción de AI/ML en la industria. Se desarrollan casos de aplicación en el sector siderúrgico, la minería, y optimización de energía en industrias de procesos, sectores de interés para el desarrollo de esta tesis.

El trabajo de Mishra et al. (2020) presenta una metodología basada en ML utilizada para mejorar la productividad del alto horno en Jindal Steel and Power Limited (JSPL), India. El artículo menciona que el impacto de la mejora en la productividad se observó luego de 18 meses de iniciado el proyecto. Las mejoras se lograron, entre otras cosas, utilizando ML y la integración con el conocimiento del dominio de los especialistas en la operación metalúrgica de un alto horno.

En este caso, los autores destacaron la importancia de los métodos de ML para mejorar la productividad y la calidad en el procesamiento de materiales de flujo continuo, como sucede en un alto horno.

Según Spadaccini et al. (2018), una plataforma de datos totalmente integrada es la base para utilizar un enfoque de análisis de datos estadísticos, potenciado por tecnologías emergentes de AI y ML. De esta manera es posible la extracción de conocimiento embebido útil para la optimización de la producción, los costos y la calidad, entre otros. La industria siderúrgica es un campo abierto en el que aplicar estas técnicas: la alta disponibilidad de datos, y la necesidad de controlar procesos complejos y multifísicos, cumplen los requisitos para una implementación exitosa de un enfoque basado en datos. Esto fue demostrado

en la planta de ABS, Acciaierie Bertoli Safau, Italia, que, junto con la experiencia de socios industriales, comenzó a utilizar análisis predictivo.

Entre otras aplicaciones de ML en el ámbito industrial se encuentra el presentado por Ruiz-Sarmiento et al. (2020) que desarrollo una metodología para aportar soluciones que permitan resolver el problema del procesamiento y renderizado de datos, y diseño de modelos predictivos. Estos han sido desplegados en una fábrica de ACERINOX Europa S.A.U para optimizar la gestión del mantenimiento de los equipos que intervienen en el proceso productivo.

El estudio de Gazola et al. (2021) en Gerdau Aços Longos SA, Brasil, presenta una solución basada en ML para evitar que palanquillas de acero con un grado diferente al especificado siga al siguiente proceso. La metodología identifica el producto de acero en el proceso de laminación. Usando una técnica de detección de valores anómalos, es posible identificar patrones en los datos para cada grado de acero, identificando cuándo no coincide con el resultado esperado en los datos simulados. Al momento de generar el artículo, los autores habían logrado resultados con el modelo funcionando off line, y estaban trabajando para realizar más pruebas durante la producción para lograr validar la eficiencia del modelo.

Siguiendo con casos en la industria del acero, Waters et al. (2021) presenta el caso de la startup tecnológica Falconry, que ofrece una plataforma de AI como una solución para resolver el desafío que genera la adopción de tecnología ML y la AI en el ámbito productivo. En este caso la aplicación de ML se basa en una técnica de clasificación de series de tiempo consistente, y repetible que presenta robustez frente a fuente de datos incompletos e irregulares. Según el artículo, esta solución genera información para reaccionar ante cambios en las condiciones de producción, a partir de los datos generados en el proceso. En el documento se presenta una discusión sobre los desafíos subyacentes en la aplicación en tiempo real en los sistemas industriales. Luego presenta un estudio de caso de cómo se aplicó ML en una planta de producción de acero para predecir la falla de equipos, y de esta manera facilitar la gestión del mantenimiento predictivo.

En el trabajo de Manojlović et al. (2022) se desarrolla un caso donde un horno eléctrico en una industria siderúrgica ha sido optimizado a través de aplicación de ML, lo que genera un menor consumo de energía del proceso productivo. En el estudio, se utilizaron diferentes métodos de procesamiento de datos y aprendizaje automático para evaluar los parámetros de eficiencia energética del horno. Los autores señalan que el conjunto de datos se recopiló durante cinco años, en una fábrica de acero, se consideraron 42 variables. El artículo da cuenta de complejidades a ser resueltas en el camino para lograr una adopción exitosa de la metodología para optimizar un proceso industrial.

El artículo de Avalos et al (2021) presenta la adopción de ML en operaciones mineras para predecir el consumo de energía en un Molino SAG. El trabajo propone una metodología que utiliza variables operativas en tiempo real para pronosticar el próximo consumo de energía a través de técnicas de aprendizaje automático y aprendizaje profundo. Se estudiaron varios métodos predictivos y se presenta un flujo de trabajo sobre cómo manejar conjuntos de datos reales y cómo encontrar modelos óptimos.

Flores & Leiva (2021) en su trabajo, abordan el uso de métodos de IA para mejorar los procesos de producción de cobre. El artículo desarrolla un caso en una operación minera en el norte de Chile, donde compararon tres modelos para predecir la recuperación de cobre por lixiviación utilizando cuatro conjuntos de datos del proceso. El artículo describe todo el proceso desde la preparación del conjunto de datos hasta la obtención final de los resultados, que dieron valores competitivos altos en comparación con los obtenidos en estudios similares utilizando otros enfoques en el contexto.

El trabajo de Barnerwold & Lotermozer (2020) observa las limitaciones que presenta el sector minero para determinar qué tecnologías digitales son más relevantes para sus necesidades de optimización de procesos. Los resultados demostraron que actualmente se consideran 107 tecnologías digitales diferentes en el sector minero. Las operaciones mineras a gran escala parecen seleccionar y aplicar tecnologías digitales adecuadas a sus necesidades, mientras que las operaciones con tasas de producción más bajas no implementan las tecnologías digitales actualmente disponibles en la misma medida. Estos productores menores pueden requerir otras soluciones de transformación digital adaptadas a sus capacidades y necesidades y aplicables a su escala de operaciones.

El artículo de Zelinska (2020) es un punto de partida muy interesante sobre el potencial del ML en la minería a través de sus diversos métodos. El artículo aborda el posible impacto para mejorar los procesos en la empresa minera y maximizar el uso de los equipos. El artículo destaca la alta dependencia de las tecnologías de la información, el análisis matemático, los especialistas en estadística. Además, el artículo también señala que la adopción de la tecnología ML es una condición prometedoras y necesaria para aumentar la eficiencia minera y garantizar la seguridad ambiental.

Ali y Fripong (2020) observan que la industria minera ha estado rezagada en la aplicación de metodologías innovadoras para lograr la autonomía de operación aplicando AI. Sin embargo, afirman que esta tendencia está cambiando y presentan un estudio que revisa y analiza todo el trabajo reciente relacionado con la automatización en la industria minera. El trabajo brinda recomendaciones para implementar Deep Learning (DL), ML y AI en el sector minero. El artículo concluye que la tecnología mencionada podría contribuir a establecer la mina del futuro, generando procesos más eficientes, efectivos y más seguros con operaciones mineras sostenibles.

El trabajo de Visser (2020) se centra en la creciente disponibilidad de información y capacidades de análisis de datos. El documento presenta un modelo para la alineación de los sistemas, el diseño organizacional y las prácticas de gestión para facilitar la adopción de la gestión de operaciones impulsada por el rendimiento en la minería y el procesamiento de minerales. El artículo destaca la necesidad de involucrar y motivar a los operadores en la metodología de mejora basada en datos y empoderarlos para tomar el control de la toma de decisiones en intervalos cortos.

Contribuyendo a establecer el marco conceptual, el artículo de Sharma et al. (2021). En este artículo, los autores destacan la lentitud de la industria minera en adoptar la digitalización en comparación con otros segmentos de la industria. Las empresas están lidiando con las presiones de los costos de operación debido a las fluctuaciones de la demanda y al aumento de los costos de operación. Los costos de mantenimiento del equipo suman alrededor del 10% al 30% de los costos directos de las operaciones mineras debido a las diferentes condiciones de operación. En el artículo se desarrolla un modelo innovador de ML que optimiza el programa de mantenimiento centrado en las acciones basadas en

datos para demostrar las métricas de la efectividad general del equipo (OEE), la efectividad del rendimiento general (OTE) y el cálculo del factor de impacto (IF). Además, la mejora del IF se demuestra a través de un estudio de caso de palas mineras. En este sentido la optimización del IF, al optimizar el tiempo de uso y el volumen producido por equipo, está alineada con la mejora de la productividad de los equipos según los ODS de la ONU.

Por último, otro trabajo que colabora en este estudio es el trabajo de Abukwaik et al. (2022), que a través de un estudio de caso empírico evalúa la eficacia y eficiencia del método propuesto en comparación con los existentes en la literatura en un proceso industrial. La investigación destaca la importancia de considerar el conocimiento del dominio industrial en la selección de características para construir un modelo de ML industrial robusto. En el trabajo definen el proceso industrial como una red compleja de miles de elementos interconectados por flujos de material, energía e información. Finalmente, el documento propone un método de selección de características para capturar el conocimiento del dominio e identificar las señales de proceso relevantes.

## **2-8 Oportunidades para el desarrollo de una nueva metodología para la incorporación de IA/ML en el ámbito Industrial**

Teniendo en cuenta los antecedentes considerados, parece no existir dudas sobre el valor agregado que aportan las soluciones basadas en AI/ML en el ámbito industrial para optimizar procesos operativos. Por otro lado, la adopción de estas soluciones aparece como una opción viable según las numerosas publicaciones académicas que dan cuenta de casos en distintos sectores industriales.

No obstante, la afirmación del párrafo anterior, se percibe la necesidad de generar metodologías y soluciones que permitan democratizar el uso de AI/ML en la industria, como elemento clave para el despliegue masivo y la excelencia en los procesos productivos.

Un artículo de Davenport (2020), que se basa en una investigación de Deloitte sobre el uso de herramientas de IA en la industria, destaca cómo han disminuido las barreras para la adopción de herramientas de inteligencia artificial. Basado en una encuesta de más de 2727 ejecutivos globales de nueve

países, y todas sus organizaciones han adoptado IA. Los hechos clave que surgen del artículo son que los encuestados sienten que la IA es cada vez más fácil y seguirá siéndolo.

Desde este artículo se desprenden dos conceptos a considerar. El primero es la preferencia por adoptar tecnología de AI desde una solución del mercado, en lugar de desarrollar algo específico para la empresa. Además, siguiendo con el primer concepto, el artículo destaca que el 74% de los ejecutivos consultados coincidieron en que “la AI se integrará en todas las aplicaciones empresariales dentro de tres años”. En términos de la práctica actual, el 50% dice que "comprará todas" sus capacidades de AI. El segundo concepto, se refiere a los riesgos que el adoptante ve sobre la AI. Algunos de los riesgos específicos que más preocuparon a los encuestados fueron problemas de ciber seguridad, fallas de IA que podrían afectar las operaciones, uso indebido de datos personales, y cambios regulatorios relacionados con IA/ML.

Por otro lado, a partir de la investigación desarrollada se puede observar que el concepto en este momento es bien conocido y dominado por Investigadores, Matemáticos e Ingenieros en el campo de la investigación operativa y de software, entre otros. Parece surgir una gran duda con respecto al conocimiento del concepto y el valor que AI/ML puede agregar en el taller para el operador del proceso. En esta línea, el trabajo de Davenport (2020) arroja algunas luces sobre el conocimiento del tema por parte de los Directivos.

Otra observación para considerar es lo que afirma Muhuri et al. (2019) sobre estudios que han demostrado que la digitalización de productos y servicios se ha convertido en una necesidad para un ecosistema industrial sólido. Sin embargo, estos requisitos y tecnologías avanzadas han hecho que los sistemas sean más complejos y han dado lugar a muchos otros desafíos, como la ciberseguridad, la confiabilidad, la integridad, etc. Estos son los principales cuellos de botella que deben superarse para el diseño y la implementación exitosa del modelo I4.0.

Entre las oportunidades que se perciben a partir de la investigación realizada, aparece la necesidad de acortar los ciclos de implementación de varios meses, dieciocho como se ve en el caso de Jindal Steel Power Limited (Mishra et al., 2020) o generar metodologías que faciliten acelerar el proceso de adopción de soluciones de AI/ML en sectores que muestran un retraso en la incorporación

de soluciones de digitalización industrial, como sucede en la Minería (Sharma et al, 2021).

Por otro lado, aparece la necesidad de involucrar a las personas, empoderarlas para la toma de decisión, y lograr el compromiso para la operación y en la metodología de mejora basada en datos. En este sentido esto se alinea sobre lo que observa Visser (2019) en su artículo.

Otra oportunidad surge en la necesidad de llevar a la solución de IA/ML al dominio industrial con todas sus particularidades y complejidades que contienen sistemas socio técnicos complejos como el ámbito de la producción. En ese sentido el artículo de Abukwaik et al. (2022) da algunas recomendaciones para que el equipo de científicos de datos sin conocimientos del proceso industrial adquiera ese conocimiento para entrenar al modelo de ML. Aquí la observación a realizar es que la adopción de modelos de ML/AI según esos autores es un terreno que le pertenece a científicos y tecnólogos sin conocimiento del entorno industrial.

Lepenioti et al (2020) observan que hay una gran cantidad de datos operativos que no se están utilizando. El artículo señala que las industrias están sentadas en una mina de oro de datos históricos, heredados y operativos inexplorados de sus sistemas de ejecución de fabricación (MES) y sistemas de planificación de recursos empresariales (ERP), entre otras fuentes de software, y no pueden darse el lujo de perderse su potencial inexplorado. Sin embargo, actualmente solo se utiliza entre el 20% y el 30% del total de dichos datos disponibles en bases de datos.

Entre los casos de aplicación en la industria aparece el caso de la startup Falconry (Waters et al., 2021). Este trabajo pone de manifiesto las posibilidades que generan las técnicas de análisis de datos para optimizar procesos industriales, y las oportunidades para generar oferta de soluciones que permiten hacer más fácil la adopción de IA/ML en empresas industriales tradicionales, como en el caso del sector siderúrgico.

Una observación sobre los casos analizados es que en general se trata de desarrollos puntuales difíciles de escalar. Se trata de casos altamente especializados en la resolución de una problemática puntual, y podrían presentar dificultades para y demostrar los beneficios de la IA/ML en el taller de producción.



Por último, aparece la oportunidad de generar metodologías que permitan adoptar AI/ML en procesos industriales, y potenciar el conocimiento experto, o conocimiento tribal (Lin et al., 2016) en el ámbito industrial. En las empresas industriales, el conocimiento tribal se refiere a información sobre un proceso que no está debidamente documentado, y en general se trata de conocimiento tácito de los operadores de procesos. Si bien el conocimiento tribal fomenta el trabajo en equipo, dificulta las mejoras de procesos y los análisis de causa raíz, especialmente porque las personas manejan información en forma individual y no siempre es compartida correctamente, lo que oculta los datos al impedir el libre intercambio de información de valor agregado. Este fenómeno se ha visto agravado por el retiro de trabajadores experimentados, y una nueva generación de profesionales más jóvenes ocupando espacios de toma de decisión en las industrias. Como resultado, las empresas deben lidiar con el desafío de tratar de asesorar a profesionales con menor experiencia, y avanzar en el conocimiento del dominio, mientras intentan estandarizar las mejores prácticas para desarrollar una ventaja competitiva.

# **CAPÍTULO 3 – Metodología propuesta y casos de aplicación**

## **3.1 Introducción**

En los capítulos anteriores se ha planteado el marco conceptual, y el estado del arte en la tecnología de interés, AI/ML, en el marco de la digitalización industrial y el modelo Industria 4.0/5.0. Para avanzar en el desarrollo de esta tesis, en este capítulo se propone y se describe, una metodología que pretende impulsar y democratizar la adopción de soluciones de AI/ML en el ámbito industrial, y de esta manera facilitar a las empresas de distintos sectores productivos, evolucionar en el modelo I4.0/I5.0.

Los artículos de Walas Mateo & Redchuk (2021, 2022) se refieren al impacto de la aplicación de soluciones de AI/ML sobre los procesos industriales. En esos artículos se presenta importante evidencia sobre los aspectos positivos que conlleva la aplicación de este tipo de soluciones en la industria, tal como se desarrolló en el capítulo anterior a través de nuevos modelos de negocio. En esa sección fue posible visibilizar los desafíos y oportunidades que aparecen para lograr una exitosa transformación del ámbito industrial a través de la adopción de soluciones de analítica prescriptiva.

Por lo tanto, a continuación, se desarrollan los conceptos que permiten establecer una metodología para que, a partir de un nuevo modelo de negocios innovador, los operadores de procesos industriales sean empoderados utilizando IA/ML. La propuesta se focaliza en una solución de ML desarrollada sobre una plataforma de bajo código (Low Code platform, LCP) que se adopta en entornos de producción, a través de un proceso de cocreación facilitado por una metodología ágil conocida como Lean Startup (Ries, 2011). Esta metodología permite lograr mejores resultados en un proceso de adopción menos complejo y lento, posibilitando la democratización de la inteligencia artificial y aprendizaje automático en entornos industriales tradicionales. Esta metodología involucra a los usuarios de la solución propuesta en el proceso de adopción desde una etapa temprana.

Por lo tanto, para avanzar en la descripción de la metodología propuesta comenzaremos con la presentación de conceptos sobre nuevos modelos de negocio, metodologías ágiles, y en particular sobre Lean Startup, fundamentos

sobre LCP. Luego se presenta la metodología propuesta, y finalmente su validación a partir del desarrollo de tres casos reales.

Al final del capítulo, se desarrollan casos de aplicación a modo de validación de la metodología propuesta. El primero se trata de una aplicación en la industria siderúrgica, otro en el proceso de industrialización del mineral de cobre en una mina de los Andes peruanos, y el último se refiere a un caso de optimización del uso de la energía en una firma de producción de alimentos.

### **3.2 Nuevos Modelos de Negocios.**

Para iniciar este tema, se debe observar la base conceptual que establece el trabajo de Oterwalder et. al (2005). Entonces, aquellos nuevos modelos de negocios cuya propuesta de valor se focaliza en AI transforman las fábricas tradicionales en ámbitos más inteligentes y eficientes, y las personas en el piso de producción pueden empoderarse a partir de la información que generan este tipo de soluciones. El trabajo de Pfau & Rimpp (2021), destaca el potencial disruptivo de la AI y, más recientemente, el ML para generar nuevos modelos de negocios y oportunidades para los emprendedores. Los autores respaldan el desarrollo conceptual con muchos casos de la práctica y concluyen que el potencial innovador de los nuevos modelos de negocios puede dar lugar a nuevos modelos operativos radicales que podrían conducir a empresas de un tipo nunca antes visto.

Sobre las tecnologías disruptivas, Borja (2020) coincide sobre el potencial disruptivo de Inteligencia Artificial, y además en ese mismo sentido considera a Blockchain, Realidad Virtual y Aumentada, y Robótica. Observa que a través de estas tecnologías aparecen oportunidades de generar nuevos modelos de negocio que generan cambios en la organización económica y social.

El trabajo de Borja (2020) además apunta que existen tres tipos diferentes de modelos de negocio disruptivos, algunos de ellos derivados de la transformación digital, la economía de plataformas, los modelos descentralizados o la economía superfluida, o líquida tal como se mencionó en el primer capítulo de este trabajo según Vashov (2015). Los nuevos modelos de negocio y las empresas que los representan se apoyan en una serie de premisas repetidas: la personalización,

el pago por uso, el modelo colaborativo, los modelos organizativos ágiles y flexibles, y el valor agregado a partir del uso de datos.

Iansiti y Lakhani (2014) propusieron tres propiedades para comprender por qué los productos conectados están cambiando los modelos de negocio: (1) A diferencia de las señales analógicas, las digitales pueden transmitirse perfectamente, sin errores. (2) Además, las señales digitales se pueden replicar indefinidamente sin ninguna degradación. (3) Una vez que se ha realizado la inversión en infraestructura de red, la página se puede comunicar al consumidor incremental a un costo marginal cero (o cercano a cero). Y una tarea digital realizada a un costo marginal cero reemplazará inmediatamente cualquier tarea analógica tradicional completada a un costo marginal significativo.

Walas Mateo & Redchuk (2020) afirman que diferentes empresas en una amplia variedad de sectores están cambiando modelos de negocio desde la comercialización y distribución de bienes físicos, para ofrecerlos como un servicio (As a Service). Este modelo, conocido como Servitización será un tema para desarrollar en futuras investigaciones, tal como se plantea en el último capítulo de este trabajo.

Por otro lado, muchas empresas se enfrentan a la creciente amenaza de la obsolescencia del mercado, la incertidumbre, y el cambio constante parecen ser condiciones de borde establecidas. Con respecto al papel del cliente y los operadores en el taller, parece que las personas tienen un papel central en los nuevos modelos operativos y de negocio. Se puede decir que cada nueva oportunidad requerirá la participación de personas y departamentos que hoy están aislados en sus silos, y generar equipos multidisciplinarios. Además, la colaboración con otras empresas serán la norma una vez que se entienda que la complejidad que enfrentan las empresas es demasiado importante para ser resuelta de forma aislada.

Una visión interesante con respecto a la innovación, las plataformas y la disrupción digital es presentados por Cozmiuc, & Petrisor (2018). Estos autores indican que los modelos de negocio se han vuelto clave en la disrupción digital, y los últimos modelos de negocios se transforman en plataformas de creación de conocimiento. Destacan la importancia de la innovación abierta como parte

de los modelos de negocio de plataforma. Por otro lado, destacan que las startups tecnológicas ingresan a los mercados sin barreras y obligan a empresas establecidas a competir con ellas en función de los modelos comerciales, y combinar la agilidad y la creatividad de las empresas emergentes. En este trabajo describen el caso de una de las principales empresas proveedora de tecnología del mundo, Siemens, y la forma en que esta gran empresa utiliza las últimas herramientas para la innovación. Se destacan innovación abierta para el desarrollo de tecnología, modelos comerciales para concretar la innovación, y por último como financia nuevos modelos de negocio. Siemens ha creado una estructura interna que tiene la intención de adoptar las ventajas de los nuevos modelos de negocio en la estructura de la empresa.

En el marco de lo descrito anteriormente, surge la iniciativa Siemens Next47. Según Walas Mateo & Redchuk (2021), Next47 es una aceleradora de startups tecnológicas desarrollada por la gran empresa tecnológica alemana. La misma apoya startups con productos y servicios para IIoT, AI/ML y otras soluciones disruptivas de digitalización.

En ese artículo Walas Mateo & Redchuk (2021), observan otro caso de cooperación entre grandes empresas tecnológicas y startups. Se trata de Gradient Ventures, el fondo de riesgo de la empresa Alphabet, Google. Esta aceleradora invierte y conecta startups en etapas tempranas con recursos del ecosistema tecnológico de la inteligencia artificial. Analizando su cartera de nuevas empresas fundadas, aparecen varias startups cuyos modelos de negocio están basados en plataformas de análisis predictivo impulsada por AI para procesos industriales.

Para finalizar este punto, se debe considerar el éxito en la adopción de los nuevos modelos de negocio. Un enfoque a considerar de acuerdo al alcance de esta tesis, es el que da Sailer et al. (2019) en un artículo donde se afirma que se identifican tres imperativos clave en las transformaciones digitales exitosas. Estos imperativos han dado forma a su metodología de Gestión Integrada del Cambio:

- Instituir un enfoque integrado a través de los hechos, es decir, amalgamar elementos tangibles como tecnologías y equipos, y elementos

intangibles como los procesos, interacciones sociales y la cultura a lo largo del viaje de transformación a través de toda la empresa.

- Generar el cambio de forma ágil actualizando proactivamente indicadores de gestión para cumplir con necesidades y objetivos generales de manera eficaz.
- Adaptar palancas de Gestión del Cambio “clásicas” como la comunicación, liderazgo, formación de equipos, etc. para las necesidades de digitalización.

### **3.3 Metodologías de desarrollo de software a través de bajo código (Low Code)**

Una alternativa al desarrollo tradicional de soluciones de software se presenta a partir de las plataformas de bajo código (LCP). El artículo de Di Ruscio et al (2022) desarrolla la evolución de la alternativa de generación de soluciones de software a través de minimizar la necesidad de programación utilizando lenguajes visuales, interfaces gráficas, y configuración.

El término "Low Code", bajo código en cuanto a la necesidad de codificación de un software, fue acuñado por primera vez por Richardson & Rimer en (2014). Este nuevo modelo de desarrollo de soluciones de software establece un nuevo paradigma de la ingeniería de software para soluciones industriales. Este modelo genera que las empresas prefieren elegir alternativas de código bajo para un desarrollo rápido, continuo, y eficiente a raíz de la menor demanda de recursos especializados en desarrollo de software que demanda este paradigma. Las LCP son ecosistemas con los que las aplicaciones pueden ser desarrolladas, minimizando la definición de código manualmente, porque ya está desarrollado y preconfigurado.

Las LCP enfatizan las interfaces visuales para permitir que las personas, sin un conocimiento de software, puedan crear e implementar aplicaciones comerciales con relativa facilidad según Waszkowski (2019). El principal objetivo de las LCP es permitir que las empresas desarrollen aplicaciones sin ingeniería compleja, que faciliten su configuración, para conseguir así, rapidez y agilidad.

Además, este tipo de plataformas también ofrecen a las empresas una forma más económica de cumplir con el mercado y/o requisitos internos de las

mismas. Por medio de las LCP, las firmas pueden crear programas o apps para dispositivos móviles o de escritorio, multifuncionales y de alta capacidades de gestión de la información.

Bock & Frank, (2021) afirman que las LCP facilitan el logro de objetivos en el núcleo de los sistemas de información comercial, como aumentar la productividad y reducir los costos de desarrollar y mantener sistemas de software empresarial. Como también, mejorar la capacidad de las organizaciones para adaptar los sistemas de software a los requisitos que cambian rápidamente y empoderar a los usuarios. Los autores también señalan que no está del todo claro qué distingue a los LCP de las herramientas de desarrollo de software tradicionales, como los entornos de desarrollo integrado (IDE) clásicos y las herramientas para el desarrollo dirigido por modelos (MDD).

El artículo de Bock & Frank, (2021) destaca que las LCP poseen algunas funcionalidades o características comunes. En particular para este estudio interesan ítems como la interfaz de programación de aplicaciones (API), y la interfaz gráfica del usuario (GUI). La primera se refiere a la capacidad de acceder a fuentes de datos externas usando una variedad de aplicaciones. La segunda se refiere a la posibilidad de visualizar resultados e información en forma amigable para el usuario, en distintas plataformas. Además, esta última funcionalidad permite integrar artefactos prediseñados que facilitan la adopción de la solución.

Cabot (2020), sostiene que utilizar un enfoque de bajo código, permite a los ingenieros de procesos aplicar rápidamente aplicaciones de datos de IA sin necesidad de conocimientos de codificación. La mayor demanda de soluciones de analítica descriptiva ha impulsado el desarrollo de alternativas de LCP. A pesar de que no es tan avanzado, los proveedores también ofrecen versiones LCP para análisis predictivo y software de aprendizaje automático que toman el análisis o ciencia de datos a través de una serie automatizada de pasos para crear modelos que luego puedan entrenar datos.

Sanchis et al. (2020) observan que expertos predicen que las LCP serán muy importantes para trabajar eficientemente y lograr mayor competitividad en las empresas. En ese sentido mencionan que herramientas de software de automatización industrial tales como las LCP, pueden ser una respuesta para

facilitar la adaptación de empresas industriales para adoptar la digitalización que promueve el modelo I4.0/I5.0. En particular para aquellas firmas con menos resiliencia y nivel de adaptabilidad.

### **3.4 Solución propuesta a través del nuevo modelo de negocio**

La propuesta de valor del nuevo modelo de negocio que emerge de este trabajo está focalizada en las oportunidades que genera la adopción de IA/ML en la industria, y la opción que se presenta a través de LCP para acelerar los procesos de adopción de nuevas soluciones, mientras se empodera a los operadores industriales.

La solución bajo estudio, es una plataforma desarrollada especialmente para que empresas industriales logren agregar valor a los datos generados en la operación. La misma consta de distintas herramientas para la visualización de los datos, el análisis de la calidad de los mismos para avanzar en el modelo, y además cuenta con plantillas pre configuradas para abordar distintas problemáticas específicas que requieren optimización, en los procesos industriales.

La plataforma de software que se analiza, ofrece seis plantillas de modelos de datos genéricas. Estas abordan las siguientes cuestiones, Pronóstico, Detección de anomalías, Optimización, Simulación, Predicción de fallas y Predicción de piezas defectuosas. La plantilla a utilizar definirá el modelo en cada caso, dependiendo de la naturaleza del proceso y de la oportunidad de mejora a abordar. La figura 5 muestra las seis opciones de plantillas y características de aplicación de cada una de ellas.

Estas plantillas, o *templates*, son artefactos preconfigurados como parte de la GUI que provee la plataforma. Esta característica, permite a los usuarios en el piso de producción, quienes son los expertos en el proceso industrial, comprender de forma visual y, por lo tanto, más amigable, los logros que se pretenden obtener con el modelo de datos. Esto acelera la evaluación del modelo y facilita obtener resultados en forma más temprana, y de esta manera lograr evaluar la efectividad de la propuesta en forma anticipada.



El ciclo de adopción comienza con el análisis de los datos, para esto la LCP provee herramientas visuales para analizar la calidad y consistencia de los datos. A través de este tipo de funcionalidad se realiza el curado de los datos, normalizando y validando los mismos. Se desarrolla un proceso de estandarización y validación de datos para eliminar las redundancias o inconsistencias, completando datos que actualizan cada registro, eliminando anomalías, y revisando los parámetros más relevantes.

Luego se procede a determinar el modelo apropiado para el caso de uso a resolver. Una vez determinado el modelo más apropiado se continúa trabajando con el modelo fuera de línea, en un espacio de cocreación. Esto significa la iteración y colaboración entre personas que poseen conocimiento del proceso industrial, y las que conocen sobre software y modelos matemáticos. Una vez generado, el modelo analítico se alimenta con datos de la base de datos del historiador, estos son datos del tipo series de tiempo. De esta forma, los usuarios evalúan los resultados que genera el modelo de datos y ganan confianza en el uso de la plataforma iterando a través de múltiples experimentos.

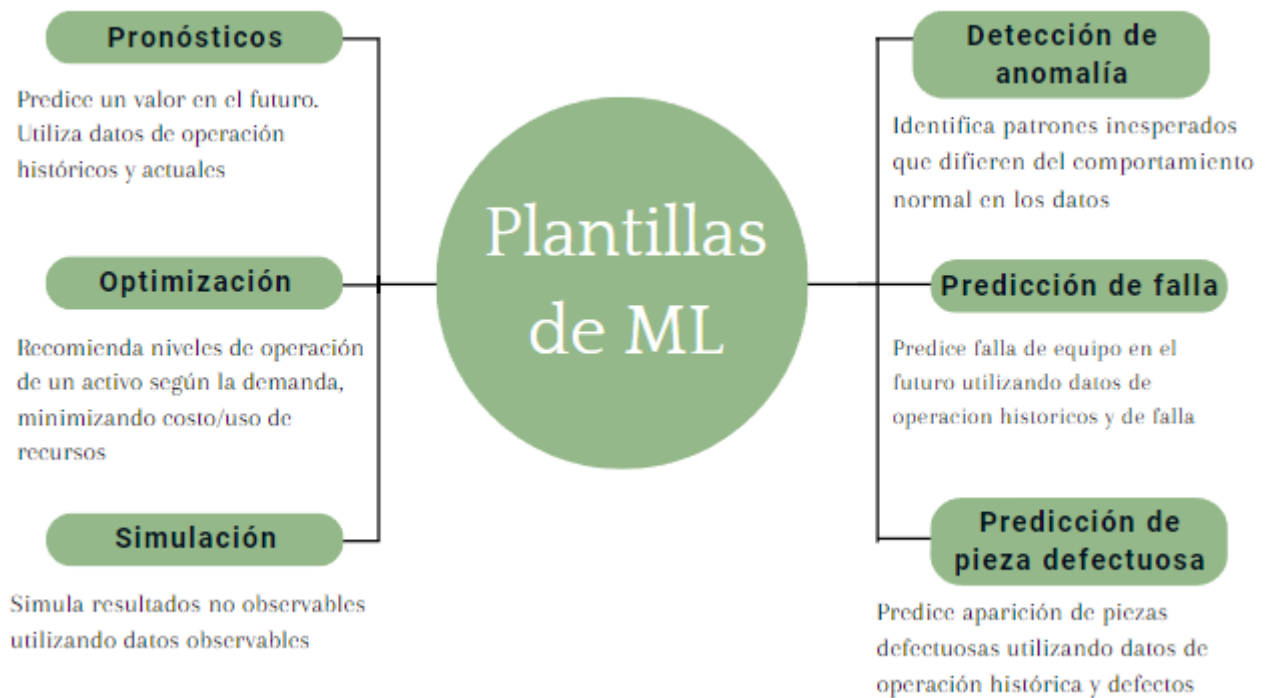


Fig. 5. Esquema de las 6 plantillas preconfiguradas que ofrece la LCP, y el alcance de cada una. Fuente: autor.

El modelo se despliega en el espacio en la nube y comienza a operar, ingestado datos en tiempo real de los procesos industriales a través de streaming. La solución se ofrece en un modelo como servicio (SaaS), ingiriendo datos en un formato de serie de tiempo desde una plataforma MES; o arquitectura IIoT. De esta manera, el software AI/ML se integra en la operación industrial con la solución de piso de producción, y trabaja con datos en tiempo real para generar las predicciones para facilitar la operación del proceso. Para esto la solución incluye APIs, que posibilitan la comunicación con las plataformas de gestión integrando los datos de la operación.

Por último, un tema complejo para el entorno industrial, y una debilidad reportada por el estudio presentado por Davenport (2020); es la ciberseguridad. Este problema se soluciona alojando la plataforma en Azure Microsoft Cloud (<https://azure.microsoft.com/>). Esta solución en la nube también proporciona la infraestructura para lograr la potencia de cálculo para los requisitos de los modelos AI/ML.

### **3.5 Metodologías ágiles como facilitadoras del cambio**

Tal como se anticipó en el capítulo 1, la gestión de proyecto a través de metodologías ágiles (APM), aparece como una necesidad para el éxito en la adopción de las nuevas prácticas y soluciones que propone el modelo I4.0/5.0.

Los enfoques de APM se basan en el desarrollo de productos iterativos e incrementales, y en la colaboración activa con el cliente o usuario. Luego de cada iteración, el cliente valida el resultado de la entrega (ej. un código de software en funcionamiento) y proporciona información de retroalimentación (Schuh et al., 2017). Esto permite un diseño más rápido de los requisitos finales, la detección temprana de discrepancias, y el desarrollo del producto ajustado a las necesidades del cliente. Algunas de las prácticas de APM más utilizadas son: planificación iterativa, reuniones diarias, pequeños equipos autoorganizados, miembros del equipo completamente dedicados, historias de usuarios, retrospectivas, integración continua y otras (Conforto et al., 2014; Diebold y Dahlem, 2014). Con base en estas prácticas, también se han desarrollado muchos métodos ágiles estructurados, siendo el más popular el scrum (Schuh et al., 2016).

Algunos de los beneficios de la aplicación de APM, son una respuesta rápida y efectiva al cambio, detección rápida de errores y feedback por parte de los clientes, mayor productividad y motivación, y mejoras en el trabajo en equipo (Kumar y Bhatia, 2012; Thesing et al., 2021). Debido a sus muchas ventajas y buenos resultados en la industria del software, muchos otros sectores de la industria también están comenzando a reconocer a APM como un nuevo enfoque de gestión prometedor. Sin embargo, debido a las características específicas del desarrollo de software, una transferencia directa de los enfoques de APM a otros sectores no es posible y tampoco sería eficaz (Schuh et al., 2016).

El desafío más obvio de APM en la fabricación es la restricción de la cuestión física. La razón de esto radica en la naturaleza incremental e iterativa de APM que se caracteriza por una entrega frecuente de un producto intermedio funcional que el cliente ya puede usar. Si bien la realización de un código de software que funcione, y se pueda enviar en breves periodos de tiempo, es un desafío, pero factible, mientras que la entrega de productos físicos a menudo es prácticamente imposible (Cooper, 2016). Por lo tanto, en la fabricación surgió la idea de un protocepto: una versión de un producto que puede representar de distintas formas el producto a lograr, desde el concepto inicial hasta un prototipo de trabajo y permite una retroalimentación temprana por parte del cliente (Cooper y Sommer, 2018).

Entre otros desafíos importantes relacionados con las limitaciones físicas, también se encuentran la modularización del producto, la producción de las herramientas necesarias, la mayor especialización requerida de los miembros del equipo, la sincronización de diferentes dominios y otros (Atzberger y Paetzold, 2019; Ullman, 2019). También existe la necesidad de un apoyo de gestión completo (Cooper y Sommer, 2018) y la voluntad del cliente de participar activamente en todo el proyecto (Atzberger y Paetzold, 2019). Otra cosa que resultó ser muy exigente en las empresas de fabricación es asegurar un equipo de proyecto dedicado (Cooper y Sommer, 2018; Edwards et al., 2019).

El artículo de Mota et al. (2022), destaca cómo el uso de metodologías ágiles contribuye para la adopción de nuevos modelos de negocio. Los autores mencionan que en este contexto las metodologías ágiles son herramientas de planificación que facilitan definir el alcance del proyecto y su cumplimiento. Entre los beneficios que genera el uso de las metodologías ágiles, según

observan los autores, se destaca la alineación entre la propuesta de valor del negocio y la respuesta a los requerimientos del usuario o cliente.

### **3.6 Metodología Lean Startup como alternativa para Gestión de Proyectos Ágiles**

Una variante a las metodologías ágiles es la que Eric Ries introduce bajo el concepto de Lean Startup. Este concepto se presenta en el libro *The Lean Startup* (2011), esta metodología inspirada en la estrategia de Gestión Lean Manufacturing, pretende generar un producto para conocer la respuesta del cliente ante la innovación lo más rápido posible. Este producto que sería un prototipo, es conocido como Producto Mínimo Viable (PMV), o MVP por su denominación en inglés. Lo que persigue esta metodología es lograr innovaciones en el menor tiempo posible con el menor esfuerzo, y poder pivotar o realizar los cambios necesarios con la opinión del cliente sobre un producto mostrable. Faiña et al (2016) indica que, frente a los tradicionales modelos de un desarrollo frontal completo del producto, se busca un producto mínimo viable (un prototipo o una demostración) con el que pueda iniciarse el proceso de ventas y la captación de información desde el mercado.

Otro elemento a considerar cuando se habla de un nuevo modelo de negocio bajo el paradigma de la Industria 4.0 es la incertidumbre. Para hacer frente a este hecho, es fundamental la detección y la respuesta rápida al planificar una nueva estrategia. Una herramienta que podría ayudar a desarrollar y encontrar un producto y modelo de negocio que realmente funcione es una metodología Agile llamada Lean Startup. El verdadero desafío es desarrollar y validar la propuesta de valor, y buscar un modelo de negocio rentable que permita consolidar las ventas y escalar el volumen de negocio.

La metodología Lean Startup creada por Eric Ries, recogiendo el adjetivo "lean" ampliamente difundido al describir métodos de producción desarrollados por Toyota y otros fabricantes japoneses para prescindir de todo lo que sobra, dificulta y alarga los procesos productivos. El objetivo fundamental de la metodología Lean Startup es acortar el ciclo de desarrollo del producto y emplear métodos de desarrollo ágiles, con pruebas de validación por parte del mercado, para adecuar los procesos a la aceptación de los clientes, ajustando y pivotando -cuando sea necesario-. Se utilizan indicadores incrementales para

medir el resultado de las acciones sobre los clientes interesados y las ventas, y se analiza y controla el modelo de crecimiento adecuado en función de los costos de adquisición, de retención de clientes y del valor de los clientes a lo largo de su ciclo de vida. En resumen, un conjunto de técnicas para hacer coincidir los procesos de desarrollo de productos con el descubrimiento y desarrollo del cliente.

Para validar la efectividad de la plataforma y tener resultados en un período más corto que los enfoques tradicionales, se utiliza una metodología Lean Startup. De esta manera, se minimizan las actividades que no agregan valor y las personas del proceso industrial pueden involucrarse antes, mientras se presenta la nueva solución. La metodología Lean Startup tiene tres principios clave: reemplazar la planificación con la experimentación, el enfoque de "salir del edificio" y, por último, el desarrollo ágil (Blank, 2013).

El proceso de experimentación se describe mediante el ciclo de retroalimentación Construir-Medir-Aprender que consta de tres pasos: construir, medir y aprender. En el primer paso, construir, es fundamental generar el MVP utilizando la menor cantidad de recursos posible después de identificar las hipótesis más importantes (Ries, 2011). El objetivo de construir un MVP es identificar el potencial de la solución propuesta (Kerr et al., 2014) y el valor para el cliente. El paso de medir tiene como objetivo recopilar datos que puedan verificar o descartar la hipótesis realizada sobre la solución a ofrecer (Ries, 2011). En el paso de aprendizaje, el objetivo es conocer las hipótesis investigadas a partir de los datos recopilados. El proceso de aprendizaje muestra si una hipótesis subyacente puede verificarse o no, e indica si el MVP es una solución viable al problema del cliente (Ries, 2011). Esto se muestra en la figura 6.

Finalmente, el trabajo de Scheuenstuhl et al. (2020) presenta una experiencia para validar la aplicación de la metodología Lean Startup para facilitar la innovación en empresas establecidas. El trabajo destaca dos puntos claves que suman a la hipótesis de esta tesis. El primero se refiere a la optimización del uso de los recursos y el logro de resultados en menor plazo que enfoques tradicionales, y el segundo aspecto es el logro de un mayor y más temprano feedback por parte de usuarios alcanzados por el proyecto de innovación.

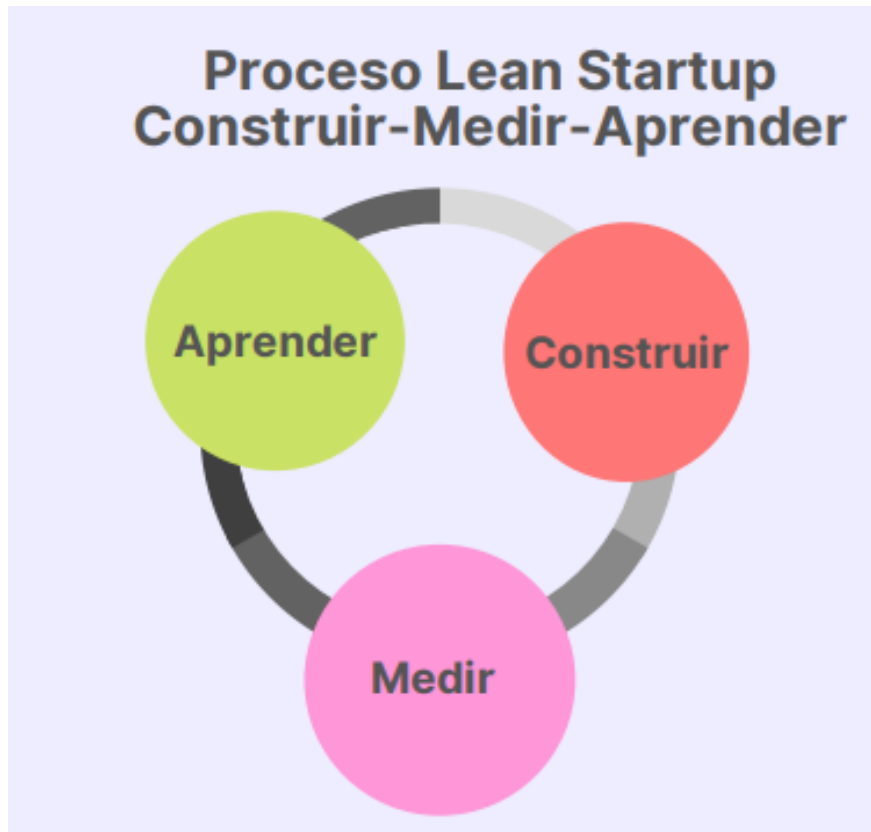


Fig. 6. Etapas del Método Lean startup. Fuente: Autor.

### 3.7 Propuesta metodológica

Luego del análisis de la problemática a abordar y el marco conceptual que se ha presentado, se detalla a continuación la propuesta metodológica que se ha generado y que constituye el aporte central de la tesis.

En primer lugar, debe observarse que para desarrollar la propuesta metodológica se ha tenido en cuenta lo que se indica en el capítulo 2, sobre la estrategia de adopción sugerida para un proyecto de ML, u otro de ciencia de datos. Se trata de combinar una implementación flexible de CRISP-DM con enfoques generales de gestión de proyectos ágiles basados en equipos para obtener los mejores resultados. En este sentido debe considerarse especialmente que los equipos a conformar, en el caso del dominio de interés, estarán constituidos tanto por profesionales del software y la ciencia de datos, como por profesionales de los procesos industriales, que aportarán el conocimiento del ámbito productivo.

Para este fin se considera la metodología Lean Startup como solución para la gestión ágil del proyecto de adopción de ML en procesos industriales. Además, se propone utilizar la solución ofrecida a través del nuevo modelo de negocios basado en la LCP, que se describió en este capítulo. Esta herramienta de software será la que permitirá generar valor sobre los datos de la operación.

Para validar la propuesta, a continuación, se desarrollan tres casos de aplicación en empresas industriales con el objetivo de ilustrar la forma en que un nuevo modelo de negocio basado en LCP para aplicar AI/ML puede motorizar la optimización de procesos industriales.

Se pretende demostrar como la metodología propuesta podría transformar un proceso de producción tradicional haciéndolo más eficiente, logrando impacto en menos tiempo que las metodologías tradicionales de AI/ML.

### **3.8 Validación de la metodología y el nuevo modelo de negocio en casos de aplicación en la industria**

A continuación, se presentan tres casos de aplicación para analizar la efectividad de la metodología propuesta, y lograr la validación.

#### **3.8.1. Caso de Aplicación en la industria del acero**

La primera experiencia a presentar es la que se desarrolló una empresa siderúrgica que necesitaba mejorar el proceso de fundición de acero de su alto horno, con foco en eficiencia energética, consistencia en la calidad, y además minimizar consumo de silicio.

Para comenzar a tratar el caso se desarrollan a continuación conceptos relacionados con el análisis de datos relacionados con la industria del acero. Luego, se describe el caso de la acería, la solución adoptada y los resultados alcanzados.

#### **Consideraciones sobre AI/ML y el funcionamiento del Alto Horno**

La primera referencia para esta sección la presenta el estudio en el trabajo de Daoutidis et al (2018). En este artículo se observa que los sistemas de procesos en la fabricación de acero son entidades complejas que involucran materias primas, productos, energía, procesos, sistemas automatizados y personas. Su

funcionamiento eficiente implica numerosas funciones y tareas. Una clasificación de uso común para los sistemas de proceso incluye planificación, programación, optimización en tiempo real y control.

Más específicamente, Mishra et al (2020), señala que los procesos que tienen lugar en un alto horno están influenciados por muchos factores, y varios de ellos interactúan entre sí. Es justo decir que el proceso es inmensamente complejo. Si bien la complejidad del proceso en los altos hornos modernos de última generación tiene el efecto positivo de permitir un límite teórico más alto tanto en la productividad como en la calidad, esto también se presta a patrones de comportamiento crónicos indeseables que se vuelven intratables, lo que conduce a una menor productividad y calidad. Es en este contexto que los métodos de aprendizaje automático se convierten en un dispositivo útil y un vehículo para el descubrimiento.

La complejidad de los procesos en el alto horno para la fundición de acero se puede observar en el trabajo de Nishioka et al. (2018). Este artículo presenta un análisis matemático para altos hornos donde se desarrolla un modelo tridimensional de estado no estacionario para expresar el comportamiento de operación de un alto horno.

### **Desarrollo del Caso**

El caso estudiado se focaliza en el proceso de fundición en el alto horno de una acería. Como se mencionó en el punto anterior, los procesos metalúrgicos en el alto horno son procesos complejos y dinámicos que generan cientos de tipos de datos con alta variabilidad. Esto genera desafíos de gestión para mantener la consistencia de la calidad de la producción, un menor consumo de energía, y minimizar el consumo de silicio.

Se debe considerar que las inconsistencias en la calidad en el proceso de fundición generan exceso de chatarra, reelaboración, y retrasos en la producción, entre otros problemas. El control de calidad tradicional se realiza a través de muestras que se analizan en un laboratorio. El problema de esta metodología es que, si se detecta alguna inconsistencia, el problema se soluciona en forma reactiva, cuando ya se produjo el material defectuoso.

Otra observación se da en el hecho de que el proceso se desarrolla en tres turnos de ocho horas, y por lo tanto los operadores son diferentes, cada uno con su



propio criterio y experiencia en el proceso. Luego, el control depende del criterio de cada persona. Además, el proceso de fundición incluye una gran cantidad de variables químicas y termodinámicas que son muy difíciles de monitorear y controlar.

Desde los procesos se generan datos en tiempo real en formato de series de tiempo y son procesados y contextualizados a través de la plataforma IIoT de clase mundial, OSI PI de OSIsoft ([www.osisoft.com](http://www.osisoft.com)).

### **Solución y Resultados**

El proyecto de mejora abordado por la empresa siderúrgica se sustentaba sobre los siguientes objetivos:

1. Identificar los parámetros que influyen en la maximización del rendimiento de producción utilizando datos de proceso generados por la plataforma de software IIoT OSI PI.
2. Predecir la calidad y el rendimiento del producto en diferentes intervalos y utilizar esas predicciones para ajustar los parámetros de control en tiempo real, maximizando así la calidad y el rendimiento del producto.
3. Aplicar una política proactiva para la resolución de problemas y anomalías del proceso basada en tener información anticipada de lo que ocurre en el proceso de fundición.
4. Institucionalizar las mejores prácticas de los operadores, y fortalecer la toma de decisiones a partir de información objetiva.

La solución LCP fue adoptada después de identificar los objetivos del proyecto mencionados anteriormente, y determinar el alcance del caso de uso.

Luego, los datos históricos se revisaron según la cantidad y la calidad para que el modelo pueda comenzar a ser entrenado a partir de esos datos. Este proceso significa estandarizar datos, filtrar anomalías, resolver datos faltantes, entre otras tareas. Luego, se realizó una fase de exploración y preparación para obtener información de los datos y prepararse para el modelado.

En la plataforma, se eligió un modelo de plantilla de pronóstico que permite predecir el comportamiento del proceso. El último paso fue entrenar el modelo con los datos históricos consolidados, y validar los resultados.

Seguidamente, la base de datos de la solución OSI PI se integró a través de una API pre configurada en la LCP. De esta forma, los datos de los procesos fueron tomados por la LCP alojada en la nube de MS Azure, a través de streaming en tiempo real. El modelo se puso en producción y luego comenzaron a generarse predicciones en tiempo real. Se monitorearon los resultados y se realizaron ajustes.

Finalmente, los resultados del modelo arrojaron predicciones para facilitar la toma de decisiones sobre los cambios en el proceso para lograr su mejora. En la Figura 7 se muestra el proceso de siete pasos que se utilizó siguiendo la metodología Lean Startup, para la incorporación de la solución de ML y el posterior logro de resultados que permitieron optimizar el proceso.

La adopción de la solución tomó unos dos meses desde el inicio del proyecto, hasta la disposición del modelo en línea incorporando datos en tiempo real, y generando predicciones para sugerir mejores condiciones de operación a los responsables del proceso en el alto horno. En este período, los operadores del proceso fueron capacitados en el uso de la solución, y sobre cómo interpretar la información entregada por la plataforma, mientras que los profesionales encargados de la plataforma ajustaron el modelo con el feedback de los responsables del proceso. Finalmente se logró la validación que fue realizada en conjunto por los ingenieros de software y los operadores de planta.

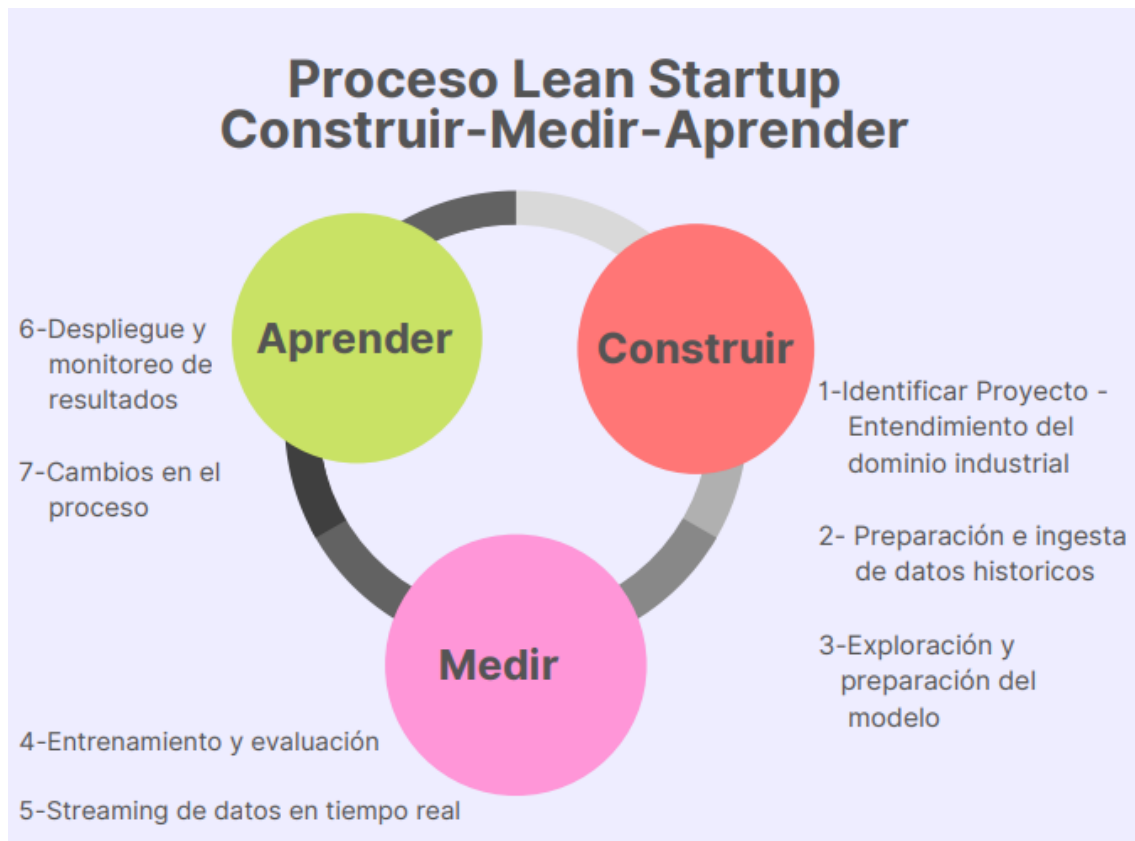


Fig. 7. Metodología aplicada en el proceso de adopción de ML en el caso de la industria del acero. Fuente: Autor.

La LCP facilitó la definición de las relaciones entre las variables que afectaron significativamente el resultado de la producción, como la cantidad de silicio agregado y el consumo de combustible. Los modelos de IA colaboraron para determinar cuál de las variables de control tienen un impacto positivo o negativo en la calidad de la producción. Al aplicar el aprendizaje reforzado con ML a través de la plantilla de pronóstico, se predijo el resultado de la producción en ciertos intervalos debidamente especificados.

Los datos históricos que se consideraron corresponden a un periodo de un año, y se analizaron parámetros como consumo de energía, temperatura, y contenido de silicio, entre otros, para generar un modelo que permitió predecir cuándo se debe acondicionar la aleación con mayor contenido de silicio, y cuándo aumentar o disminuir la temperatura del horno. De esta forma, es posible trabajar de manera proactiva, y el operador del horno recibe información con anticipación para la toma de decisiones precisas.

Como resultado del uso de datos generados en la operación de la acería, y procesados en la LCP mediante un modelo de ML, la firma siderúrgica obtuvo

una ventaja competitiva al mejorar los procesos y lograr mayor consistencia en la calidad, ajustando el contenido de silicio siempre en un rango apropiado. Además, al definir puntos de control en tiempo real para el consumo de combustible, se facilitó el ahorro de energía. La firma también redujo el porcentaje de chatarra, reduciendo así los costos y produciendo acero de mayor calidad. Todo esto ha permitido generar una triple optimización para la empresa: reducir costos, mejorar los servicios al cliente, y mejorar la rentabilidad.

El uso de métodos ML empleados junto con el conocimiento del dominio de los especialistas en el proceso industrial y metalurgia, facilitó un mayor conocimiento del proceso para las personas involucradas que se incrementó continuamente. Esto permitió trabajar en mejoras permanentes y lograr mejores KPI, y la evolución hacia sistemas de gestión más maduros.

### **3.8.2 Caso de Aplicación en la Minería**

El siguiente caso de aplicación es una experiencia en el sector minero, el mismo se desarrolló en una mina de cobre en los Andes Sudamericanos, donde existía interés por mejorar el OEE. En este sentido se decidió explorar la utilidad de la metodología en el proceso de molienda poniendo foco en un molino del tipo SAG (Semi Autogenous Mill). Al introducir la solución de AI/ML en la molienda, se pretendía maximizar el tonelaje procesado, manteniendo estable el índice P80 (Chelgani et al., 2021), que se refiere al tamaño de las partículas de Cu, mientras se maximiza la recuperación de material.

El proceso industrial de la mina se describe en la figura 8, e incluye las siguientes etapas o áreas:

- Chancado Primario: reduce el tamaño de las rocas a menos de 8" por medio de molinos de bola.
- Transporte y recuperación de gruesos: fajas de transporte (6 km), ruma de gruesos (con capacidad de 55,000 tons), y alimentadores que dosifican el mineral hacia Molienda.
- Molienda: se reduce el tamaño del mineral, según el índice P80 a 240um

- Chancado de Pebbles: proceso auxiliar que ayuda al molino SAG a procesar el mineral que alcanza el tamaño crítico. El producto vuelve a ingresar al SAG.
- Flotación: Se captura y separa las partículas ricas en cobre, se obtiene una pulpa rica en cobre llamado concentrado.
- Remolienda: se continua la reducción de tamaño de las partículas con contenido de cobre. La reducción de tamaño es necesaria para liberar el cobre.
- Espesado de concentrado: Primera etapa de reducción de contenido de agua, a una densidad mayor de 1.6
- Filtrado de concentrado: Se continua con la reducción de contenido de agua, el objetivo es lograr una humedad menor al 8%.

En esta última instancia el material debe tener el tamaño de grano adecuado para un filtrado eficiente. Los expertos del proceso de la mina identificaron esto como una oportunidad de mejora, mantener estable el índice P80, y maximizar la recuperación del material.

Los principales insumos del proceso son las características del mineral (granulometría, tipo, dureza, elementos presentes, etc.) y la tasa de alimentación. Los resultados son las características del concentrado (porcentaje de humedad, contenido de cobre, granulometría y otros).

## PROCESO INDUSTRIAL EN LA MINA DE COBRE

El proceso industrial en la planta incluye las siguientes actividades

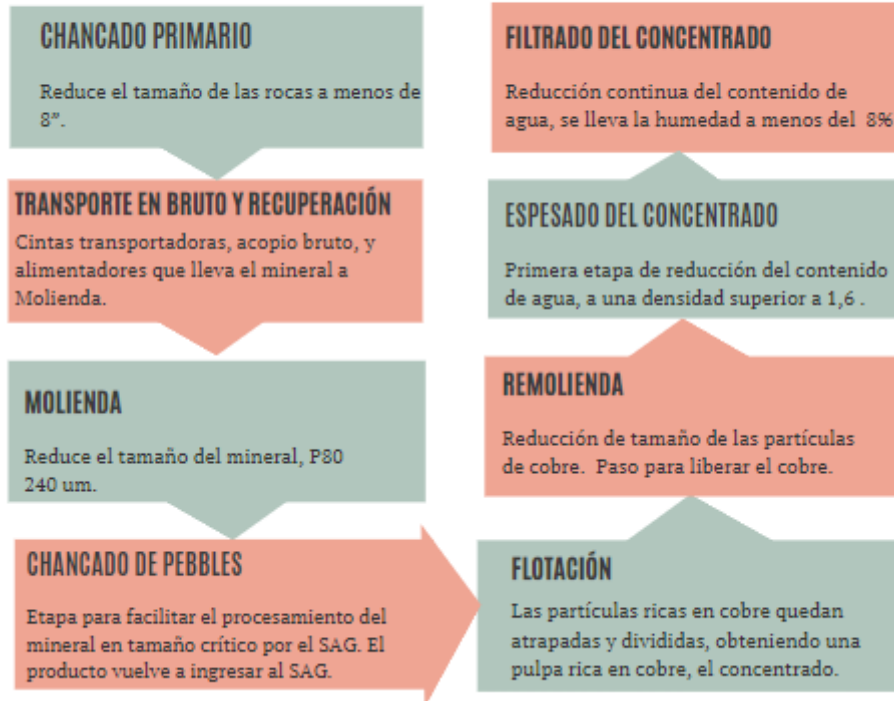


Fig. 8. Proceso industrial en la mina de cobre. Fuente: Autor

Los expertos en la operación en la mina observaron que la alimentación al molino SAG podía incrementarse siempre que exista capacidad ociosa. Al momento de comenzar el proyecto el tonelaje procesados por el SAG no era muy alto, la producción de pebbles era menor a 800 ton/h, los molinos de bolas utilizados en el proceso contaban con potencia disponible, y el P80 era menor a 240um.

En este proceso los parámetros posibles a ajustar eran los siguientes: Volumen de alimentación del SAG, Volumen de Pebbles entregado al SAG, Porcentaje de sólidos en el SAG (relación de mineral vs. agua en el SAG), Velocidad del SAG, entre otros. La figura 9 muestra un esquema del molino y el proceso, junto con las variables involucradas.




Fig. 9. Esquema del proceso en el molino SAG con indicadores relevantes. Fuente: Autor.

Cabe señalar que, si bien existe un sistema experto que controla el molino SAG, la mayoría de los parámetros son establecidos por el operador, al igual que en caso de la empresa siderúrgica en este caso también aparecen inconsistencias debido a los distintos criterios que aplica cada operador. El sistema automatizado puede manipular la alimentación del molino, la velocidad SAG y el porcentaje de sólidos SAG, pero opera el 70% del tiempo.

Una última observación importante es que la empresa genera datos en tiempo real de los procesos de producción y son gestionados a través de una plataforma IIoT. Estos datos se almacenaron en bases de datos en la nube. Por lo tanto, la empresa tiene una cantidad muy valiosa de datos para alimentar el modelo fuera de línea y de esta manera entrenarlo.

## **Desarrollo del caso y resultados**

El caso se desarrolló utilizando la metodología propuesta según Lean Startup, el ciclo Construir-Medir-Aprender. La primera fase, CONSTRUIR, comenzó después de comprometer a las personas, los procesos y la tecnología. Eso significa establecer un equipo de IA liderado por el ingeniero jefe de procesos, y que se incluyó también a miembros de los equipos de informática y automatización, y de operaciones de la mina, luego se estableció el alcance del caso de uso y sus objetivos.

Una observación importante es que se verificó que existían suficientes datos disponibles generados por la solución IIoT en la base de datos en la nube, solo era necesario normalizarlos. Paso siguiente, los ingenieros de procesos de la mina comenzaron a trabajar con los expertos en análisis de datos y matemática de la plataforma de software, para analizar y comprender la metodología y los detalles técnicos del proceso de molienda.

Una de las tareas de esta primera parte de la metodología es preparar los datos históricos, para ello fueron sometidos a un proceso de limpieza y normalización.

1-VARIABLES no relacionadas con el proceso fueron identificadas y descartadas, así como variables con una alta proporción de valores faltantes;

2- Las observaciones con valores faltantes fueron eliminadas o completadas con un valor arbitrario (por ejemplo, la media de la columna), dependiendo de la naturaleza de las variables.

3-Las distribuciones de las variables en el conjunto de datos resultante fueron examinadas para identificar valores anómalos, y se determinó si representaban errores de medición, errores de registro o valores verdaderos, y fueron tratados según su naturaleza.

Se decidió que para mejorar el proceso en el Molino SAG se utilizaría el template de pronóstico de la plataforma de software. En ese sentido el objetivo era pronosticar tonelaje tratado, energía específica, P80 y recuperación. Se espera tener predicciones con una anticipación de doce horas.

El equipo de AI de la mina se entrenó con el apoyo de expertos en análisis de datos de la Startup de software. Mientras tanto, los expertos en procesos de la mina colaboraron con los profesionales en datos de la plataforma para aclarar



dudas, realizar ajustes, e internalizar temas específicos sobre la metalurgia y los procesos característicos de la mina de cobre. El primer paso de la metodología tomó tres semanas.

La siguiente etapa siguiendo la metodología Lean Startup fue la de MEDIR. En esta fase, se generó un modelo en la plataforma de software y los usuarios de la mina evaluaron el caso de uso a partir de trabajar con los datos históricos en la plataforma.

Se realizó una exploración de los datos que arrojaba el modelo, y fueron evaluados por los expertos de procesos de la mina, y los profesionales en análisis de datos y de la puesta en marcha del software brindaron apoyo en todo momento. Los ingenieros de proceso experimentaron con el modelo, y finalmente lo validaron.

Esta fase de la metodología se completó con la puesta en marcha del modelo en la plataforma en línea. Los datos en tiempo real producidos por la solución IIoT comenzaron a incorporarse a la solución de ML instalada en la nube. Toda la integración fue realizada por especialistas en software de la Startup. La API embebida en la LCP simplificó la integración con la plataforma IIoT. De esta forma, los usuarios de la mina accedieron a la solución ML y contaron con el soporte continuo del proveedor de software. Esta etapa duró seis semanas.

La última etapa, la denominada APRENDER, con la plataforma de ML en producción y procesando datos de la operación en tiempo real permitió evaluar el valor que aportó el caso de uso. Los resultados fueron analizados por el proveedor de software, y los ingenieros de la mina. El caso de uso se revisó en una sesión de mapeo de plataforma en la que ambos equipos obtuvieron conocimientos más profundos sobre los datos, el valor comercial, y la complejidad de otros casos de uso previamente identificados.

A partir del streaming de datos en tiempo real entre el proceso instrumentado, la plataforma de ML, y el sistema de control se podría lograr un lazo cerrado que permitiría la automatización sin intervención humana. De todas maneras, esa opción se descartó, y se mantiene el operador.

Las predicciones se muestran como parte de la pantalla de control que visualiza el operador del proceso. Cuando el operador activa el modo automático, el sistema de control toma directamente la predicción que genera la plataforma de

ML, como un valor sugerido para ajustar los sesgos del molino. Esto permite que el proceso automatice la optimización sin la intervención del personal de operaciones. Finalmente, se capacitó a todo el personal del equipo de proceso, se adoptó la plataforma, y se modificó el proceso para seguir las notificaciones de la plataforma respecto al desempeño del Molino SAG. La tercera fase tomó unas 2 semanas.

Finalmente, como conclusión preliminar se puede decir que a través de la metodología propuesta se generó un proceso de cocreación entre expertos de software y análisis de datos, y los profesionales del proceso de la firma minera. Este proceso dio como resultado la aplicación de ML para optimizar un proceso industrial, y se logró demostrar el valor de la IA para la mina en sus operaciones diarias. Con confianza en las predicciones, la automatización del Molino SAG se ha incorporado como procedimiento de producción, y se ha generado un proceso de mejora continua apoyado por el nuevo procedimiento.

El equipo de operaciones actualmente está trabajando en oportunidades de mejora que se transformen en oportunidades para expandir el uso de la IA a otros procesos, y escalar la adopción en la empresa.

### **3.8.3 Caso de aplicación en la industria alimenticia para lograr eficiencia energética**

La siguiente experiencia a presentar es el desarrollo de un caso de uso en una empresa de producción de ingredientes para alimentos. El proyecto de adopción de ML se encuadra en la estrategia de optimización de sus operaciones.

De acuerdo a la metodología propuesta, la primera etapa comenzó después de definir el caso de uso, su alcance de la adopción y sus objetivos. Una de las oportunidades de mejora o “Puntos débiles” identificados fue hacer que sus procesos de producción de energía sean más eficientes. La energía era el segundo costo detrás de las materias prima, y además la empresa tiene el objetivo de reducir las emisiones de CO<sub>2</sub> en un 25% para el año 2030.

El equipo de operaciones industriales consideró oportuno utilizar AI para predecir la eficiencia térmica de cada caldera de forma tal que el consumo de gas pueda optimizarse de acuerdo con la predicción de eficiencia. El proceso se

ajusta perfectamente a los objetivos de la organización de reducir el consumo de energía, los costos de funcionamiento, y el uso adecuado en términos de preservación de activos en cuanto a las turbinas, y el mencionado objetivo con respecto a las emisiones de carbono.

Los expertos en procesos de la empresa de alimentos se capacitaron sobre el funcionamiento de la plataforma con el apoyo de expertos en análisis de datos del proveedor de la misma. Mientras tanto, los expertos en procesos industriales colaboran con los expertos en datos de la plataforma AI/ML para aclarar dudas, y temas específicos sobre las características del proceso a mejorar.

La empresa industrial utiliza turbinas y calderas de gas natural para generar vapor para la planta. Aunque las calderas fueron adquiridas al mismo proveedor, el comportamiento de cada dispositivo difiere según cambios en el ambiente. El rendimiento térmico de cada caldera puede fluctuar debido a diferentes configuraciones de piping, condiciones ambientales y asimetrías en el desgaste, lo que significa que consumían la misma tasa de gas natural pero no necesariamente generan el mismo throughput. La figura 10 muestra un esquema de cómo funciona el sistema de generación de energía de la planta.

En cuanto a la infraestructura OT/IT, la firma cuenta con una arquitectura robusta, integrada de acuerdo con los estándares ISA95. Los datos en tiempo real de los procesos de producción se generan y almacenan en bases de datos de tipo historizador. Por lo tanto, la empresa tiene una cantidad muy valiosa de datos de proceso para alimentar el modelo fuera de línea y avanzar en el caso de uso.

Para optimizar la eficiencia de la operación de la caldera, el equipo de operaciones necesitaba pronosticar el gradiente óptimo del flujo de ingreso de combustible entre las calderas. Por lo tanto, se analizaron las alternativas de la LCP, y se decidió utilizar las plantillas para elaborar modelos de ML de la plataforma de software para configurar tres modelos:

- Modelo de simulador de caldera: para predecir el consumo esperado de combustible
- Modelo de optimización de parámetros de control para identificar los setpoints que minimizarían el consumo total de combustible de las 3 calderas

- Modelo de consumo de combustible: para predecir cómo los diferentes parámetros impactan en el consumo de combustible.

Usando la funcionalidad de análisis de datos de la LCP, el equipo de operaciones revisó 18 meses de datos generados por las turbinas y calderas de gas, y datos de ambiente. Entre los datos considerados para nutrir el modelo se incluyen, datos de las calderas como presión, temperatura, consumo de combustible en cada una de ellas, y datos de ambiente como temperatura, humedad, velocidad del viento, dirección del viento.

A través de las herramientas de análisis visual de datos, el equipo de operaciones pudo detectar datos faltantes, determinar los parámetros relevantes para el modelo, la correlación de relaciones, y los valores anómalos en el proceso.

Con la combinación de los tres modelos, y con los datos históricos normalizados y validados, se llegó al MVP para avanzar en el entrenamiento del mismo en la siguiente etapa propuesta por la metodología.

Durante la etapa MEDIR, se produjo un modelo en la plataforma de software y los usuarios en el proceso evaluaron el caso de uso mediante la ingestión de datos históricos en la plataforma.

La plataforma LCP entrenó los modelos de AI con los datos históricos fuera de línea previamente normalizados. La plataforma determinó automáticamente el mejor modelo mediante la validación cruzada de los datos históricos. Además, la plataforma se utilizó para configurar un modelo de simulador para cada caldera para lograr predecir el consumo de combustible esperado según la demanda de vapor de la planta, así como las condiciones de operación de la turbina y la caldera.

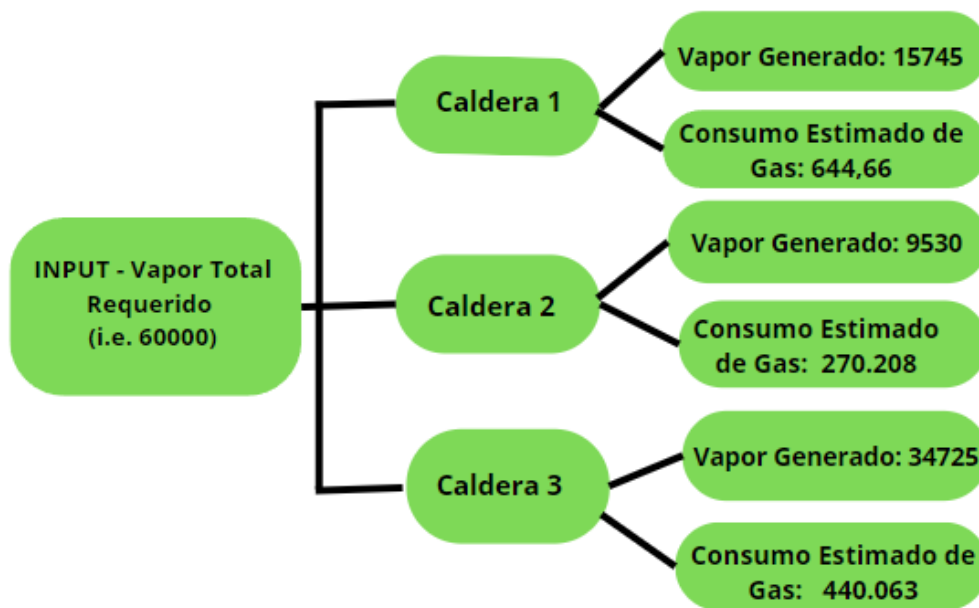


Figura 10. Considerando la eficiencia térmica de cada caldera, el problema a resolver es estimar la cantidad de combustible óptimo requerida para cada caldera asegurando cubrir la demanda de vapor requerida. Fuente: Autor.

A continuación, se configuró un modelo optimizador sobre estos modelos de simuladores de calderas para identificar los parámetros de control óptimos que minimizarían el consumo total de combustible de todo el conjunto, respetando las limitaciones físicas y de seguridad de cada caldera. El equipo de operaciones configuró un modelo de simulación adicional para predecir cómo los diferentes parámetros afectan el consumo de combustible.

Se realizó una exploración de datos y la evaluación del modelo de datos por parte de los expertos del proceso, y profesionales de software de la startup proveedora brindaron apoyo en todo momento. Los ingenieros de proceso luego de sugerir ajustes, finalmente lo validaron.

La segunda fase de la metodología se completó con la puesta en marcha del modelo en la plataforma en línea. El tiempo real de la solución IIoT comenzó a incorporarse a la solución basada en la nube. Toda la integración fue realizada por especialistas en software de la startup. Además, como la solución de software tiene posee una API para conectarse con plataformas IIoT se simplificó el proceso de integración con la plataforma de gestión de los datos operativos.

Los usuarios de la planta accedieron a la solución ML para conocer las predicciones. Contaron con el soporte continuo del proveedor de software para poder conocer mejor la plataforma, y adaptarse al nuevo entorno.

Finalmente, en la última etapa de la puesta en marcha del caso de uso el personal de producción reconoció el valor que aportaba el caso de uso. Los resultados fueron analizados por el proveedor de software y los ingenieros de procesos. El caso de uso se revisó en una sesión de mapeo de la plataforma en la que ambos equipos obtuvieron conocimientos más profundos sobre los datos, el valor comercial y la complejidad de los casos de uso previamente identificados.

Una vez que los modelos de AI se activaron en producción, el equipo de operaciones usó la plataforma para refinar los procedimientos de trabajo, y aplicar reglas al entorno operativo específico de la empresa. En la fase de prueba se observó una mejora del 2,5 % en el rendimiento térmico con respecto a los informes anteriores.

La infraestructura de entrenamiento de modelos automatizados de LCP garantiza que los modelos de AI mejoren continuamente con nuevos datos del proceso de generación de vapor.

Además, se capacitó a todo el personal del equipo de proceso, se adoptó la plataforma, y se adaptó el proceso para seguir las notificaciones de la plataforma. La tercera fase se ejecutó en 3 semanas.

En función de la eficiencia térmica de cada caldera, la plataforma LCP estima el combustible óptimo necesario para cada caldera mientras garantiza que la producción general de vapor satisfaga la demanda de la planta.

Una vez analizados los resultados, el equipo de mejora continua y el equipo de operaciones de la empresa propusieron modificar el intervalo de generación de pronósticos de consumo, llevándolos a periodos de tiempo más cortos.

### **3.9. Resultados y discusión sobre los casos**

A partir del estudio de los casos, se desarrolla a continuación las conclusiones preliminares que se completarán en el capítulo 4.

En principio se puede observar que en los tres casos se generaron resultados positivos tras el desarrollo de los casos de uso. La mejora de proceso se basó en análisis predictivos destinados a explotar los datos operativos generados por la infraestructura digital existente en las empresas analizadas.

Los casos resultan útiles para demostrar como las soluciones de AI logran impactar positivamente en una empresa tradicional. La adopción del LCP a través de una metodología ágil impacta en acortar los tiempos de adopción, y en facilitar la co-creación del modelo entre el profesional experto en la industria y el del software.

Una primera consideración para la aplicación de la metodología propuesta es la necesidad de una infraestructura IIoT que genere datos de la operación en forma consistente, y gran cantidad de datos históricos. Además, no solo importa la cantidad, sino la calidad de los datos considerados (datos faltantes, anomalías, descripción de la problemática, entre otras). Esto es una limitación importante para varias industrias tradicionales que aún están rezagadas en la digitalización. Este problema es una debilidad importante de las industrias que podrían usar modelos de datos para abordar cuestiones críticas como mejorar la vida útil restante (RUL) de los equipos pesados, reducir la huella de carbono, optimizar la gestión del mantenimiento, y reducir las actividades que no agregan valor, entre otras oportunidades desperdiciadas.

Los tres casos presentados muestran la ventaja de utilizar la metodología propuesta para optimizar procesos industriales. Debe observarse que en todos los casos las empresas contaban con una infraestructura digital relativamente madura, de acuerdo a estándares como ISA 95. En los casos estudiados el proceso de adopción se facilitaba al contar con datos históricos, y sobre todo con plataformas robustas que generan datos de los procesos en tiempo real para nutrir a la plataforma de ML desplegada en la nube.

Un tema central a considerar está referido a la posibilidad de contextualización y adaptación al dominio industrial específico que se desea optimizar. En los 3 casos se resolvieron problemáticas complejas de optimizar, donde las características de los procesos sobre los que se aplicó la metodología son muy diferentes.

Continuando con lo que se menciona en el párrafo anterior, la funcionalidad GUI visual y amigable de la LCP, junto con la utilización de la metodología Lean Startup, permite desarrollar una metodología de creación conjunta entre los profesionales de la ciencia de datos y software, y los expertos en el dominio industrial a optimizar. Esto facilita el proceso de adopción de ML, reduciendo el tiempo desde la preparación de datos hasta el entrenamiento del modelo, su validación y puesta en producción. Esto se debe en parte a la participación temprana del personal de procesos industriales y al uso de la preparación de datos automatizada de la plataforma y las capacidades del modelo de construcción de IA.

En los tres casos la LCP se integró con plataformas de gestión de las operaciones existentes, las plataformas IIoT de la acería, la empresa minera, y la de alimentos. Esta integración no resultó en un tema crítico en ninguno de los casos, esto es facilitado por la API que incorpora la LCP. Más allá, que se deben realizar acciones sobre esta integración, el tema no resulta un aspecto crítico para la adopción de la solución de ML.

Por lo tanto, de acuerdo a las observaciones planteadas en este punto se debe considerar que más allá de la metodología a aplicar, es necesario cumplir con algunas condiciones requeridas para desarrollar modelos analíticos. Esto es, disponibilidad de datos, calidad de datos, variables de proceso relevantes que forman parte de la instrumentación del proceso y la disponibilidad de expertos de dominio experimentados que puedan trabajar en un equipo multidisciplinario junto con científicos de datos, y expertos de software. Esto es un condicionante importante para crear valor a través de los datos, y debe evaluarse antes de comenzar a aplicar la metodología propuesta.

Se observa, de acuerdo a los resultados de los casos que el valor potencial a generar para la operación de la firma implica un retorno sustancial sobre inversión y podría permitir a las organizaciones desarrollar nuevas estrategias diferenciadoras en el mercado.

El potencial del enfoque propuesto es alto en las industrias tradicionales que aún no se han evolucionado al modelo I4.0/5.0 y, en la mayoría de los casos, comienzan a desarrollar la infraestructura tecnológica para alcanzar un nivel



de madurez tecnológica que permita trabajar con el análisis de datos y el aprendizaje automático para la optimización de sus procesos de producción.

## **CAPÍTULO 4**

### **Conclusiones y Futuras Líneas de Investigación**

#### **4.1 Introducción**

En el siguiente capítulo desarrollamos las principales conclusiones que resultan del trabajo de investigación, conclusiones sobre el aprendizaje que dejó este trabajo. Por último, se presentan las futuras líneas de investigación en la que se propone avanzar a partir de los hallazgos que dejó el proceso de elaboración de la tesis que se presenta.

#### **4.2 Conclusiones**

La primera conclusión que se desprende del trabajo se refiere a la necesidad de contar con un nivel de madurez digital avanzado para poder utilizar AI/ML para optimizar procesos industriales. Esto es una condición excluyente para avanzar en la adopción de AI en la industria.

La observación del punto anterior podría ser una debilidad para muchas industrias tradicionales. Los casos se desarrollaron en plantas con una arquitectura madura que facilitó la evolución hacia el uso de AI, esta es una fortaleza para estas empresas que no es común en muchas otras firmas industriales, en particular en el segmento PyME. Uno de los puntos a tener en cuenta en esta línea, es la existencia de gran cantidad, alrededor de 18 meses, de datos de alta calidad, con un bajo porcentaje de valores faltantes y anomalías.

Por otro lado, aparece la necesidad de integración de la solución con otras arquitecturas como plataformas MES o IIoT, y el alojamiento en la nube, todas de terceros. Esta vinculación en un ecosistema facilita la adopción de AI proporcionando la arquitectura necesaria en términos de alto uso de recursos computacionales y herramientas de ciberseguridad. De esta manera la LCP trabaja en una arquitectura multitenant en la nube que resulta confiable.

La metodología de adopción, y las características de la LCP también impactan en lograr uno de los pilares de I5.0, la centralidad de las personas. Los ingenieros de proceso que son involucrados desde el primer momento, y luego

comprenden la solución y sus beneficios, logrando un fuerte compromiso con la solución y el proyecto de mejora. La solución final consiste en un sistema humano empoderado, donde el operador observa las predicciones de IA, y realiza cambios en el proceso en consecuencia, logrando la automatización para la mejora de proceso, impulsada por la IA.

A lo largo de este trabajo se pudo validar que la aplicación de IA desempeña un papel central en la mejora de las operaciones de la empresa industrial, y en la disminución de la huella de carbono. Esto es posible siempre que se logre preparar a la organización para la IA, alineando a las personas, y logrando si compromiso, procesos y tecnología.

En este punto se puede considerar que la estrategia de adopción que propone el modelo de negocio a través de la plataforma de bajo código parece apropiada para dinamizar los procesos de evolución hacia la optimización de procesos industriales a partir de modelos analíticos.

A continuación, se desarrolla un análisis más detallado de la afirmación del párrafo anterior respondiendo las preguntas planteadas en el primer capítulo de esta tesis.

La solución propuesta presenta una ventaja sobre otras metodologías de adopción AI en la industria. La propuesta desarrollada en la tesis disminuye los plazos y simplificaban la adopción de la analítica en la industria. La característica distintiva del enfoque con respecto a otras alternativas es el enfoque bajo código y la metodología ágil Lean Startup, que facilita el uso de AI/ML por parte de los operadores de procesos con poco conocimiento de matemáticas o estadísticas, y baja radicalmente los tiempos de adopción.

De acuerdo con el párrafo anterior, la gestión del cambio se simplificó hacia un enfoque ágil; el nuevo modelo de negocio generó resultados más rápidos y con menor complejidad que las soluciones analíticas tradicionales. Esto se debe a que el modelo propuesto está centrado en el usuario final, el operador del proceso. El modelo bajo código facilita las tareas críticas y que consumen mucho tiempo relacionadas con el desarrollo de software y los algoritmos. De esta forma, el modelo de negocio propuesto en este caso valida como la posibilidad de democratizar la IA/ML en las industrias tradicionales, facilitando la adopción de este tipo de herramientas para segmentos industriales tradicionales, y con mayor inercia para evolucionar al modelo I4.0/5.0.

Un punto clave que simplifica la metodología ágil y la LCP es la preparación de las personas de los procesos, los usuarios de los resultados de las predicciones a través de ML. La propuesta presentada en la tesis facilita la cocreación, es decir la vinculación e iteración de expertos de software y analítica con los expertos del dominio industrial. Esto facilita por un lado poder integrar información tanto del contexto industrial, como de aspectos de software y matemática. Las herramientas visuales e interface gráfica de la LCP dinamizan el proceso de aprendizaje y la internalización de la solución por parte de los actores industriales.

Otra cuestión que se plantea en la hipótesis, es como se logra conocer en forma temprana si el proceso de adopción de una solución de ML tendrá impacto. En línea con el párrafo anterior las herramientas visuales permiten analizar el modelo, que se transforma en el PMV, y experimentar para validarlo y lograr el modelo ajustado que será puesto en producción.

Por último, se observa que las posibilidades que generan los modelos analíticos para la optimización de procesos, junto con la dinámica del desarrollo de soluciones de software a partir del modelo de bajo código. Todo esto hace que el surgimiento de nuevos modelos de negocio para dinamizar la estrategia de adopción de IA/ML en la industria tenga un alto potencial. Este tema se profundizará en una de las futuras líneas de investigación.

### **4.3 Futuras Líneas de Investigación**

#### **4.3.1 Las personas y las habilidades digitales para el modelo I 5.0, el operador 5.0**

Las futuras líneas de investigación sobre este tema deberían incluir nuevas metodologías de aprendizaje y formación acordes con el paradigma digital que faciliten la formación de las personas del proceso industrial para hacer frente a las nuevas habilidades necesarias en el escenario digital. El aprendizaje inmersivo o la gamificación, entre otros, deben usarse para facilitar la adopción de la solución de IA en la planta.

Desarrollo de habilidades digitales en las personas, learning by playing, Serious games, entre otras metodologías.

En este sentido se continuará indagando a partir de los hallazgos en el trabajo de Walas Mateo & Redchuk (2021), donde a partir de un estudio bibliométrico sobre las personas en el modelo I4.0, se destaca la brecha que existe en el manejo de habilidades digitales en las personas vinculadas a los procesos industriales, para abordar el cambio de paradigma.

Por otro lado, según Cotta et al (2020) el modelo I5.0 resuelve la mayoría de los problemas de fabricación asociados con eliminar trabajadores del taller. Sin embargo, debe incorporar habilidades adicionales con visión de futuro ya que los humanos pueden agregar habilidades de fabricación innovadoras.

#### **4.3.2 Soluciones a través de nuevos modelos de negocio y las oportunidades del paradigma de bajo código.**

Otro punto a destacar son las oportunidades que el paradigma de la fabricación inteligente abre a las startups y sus innovadores modelos de negocio que ofrecen soluciones para facilitar la adopción de AI/ML en la industria. La dinámica evolutiva que presenta el modelo I4.0 aumentan la presión y las exigencias de las personas que trabajan en la automatización, que es uno de los principales motivadores de la Industria 5.0.

Esta tesis mostró cómo un modelo de negocio que utiliza AI/ML centrado en una estrategia de bajo código podría acortar los ciclos de implementación de varios meses (18 como se vio en el caso de Jindal Steel y Power Limited) a un par de meses, tal como se muestra en los casos desarrollados en este trabajo.

La solución presentada por la IA Operacional de Falconry en la sección 2 del trabajo para mejorar el mantenimiento de los equipos. El caso de Falconry podría estudiarse a fondo para ampliar los conceptos de este trabajo y se considera para próximos pasos en esta investigación.

Por otro lado, como se ha visto en este trabajo el desarrollo de software para la digitalización industrial se ha convertido en un tema crítico, ya que tanto el conocimiento del dominio como las habilidades de programación son necesarios para un software mantenible de alta calidad.

Para analizar el potencial de esta línea de investigación se realizó un estudio bibliométrico preliminar con el siguiente Query:

"low-Code" OR "No-Code" OR "low code" OR "no-code" AND "industry 4.0" OR "smart manufacturing" OR "business models" OR "industry 5.0"

La búsqueda arrojó 14 documentos desde 2018 al 2021, y muestra la figura 11. Lo que parecería ser un tema cuyo interés se encuentra en crecimiento en la comunidad científica.




Fig. 11. Documentos por año sobre el tema. Fuente: SCOPUS.

#### **4.3.3 Modelos de negocio orientado al servicio. Servitización**

Según la lógica del mundo digital, las máquinas poco a poco dejarán de ser productos y se convertirán en servicios. En lugar de comprar un motor, el cliente va a comprar un servicio de ventilación, generación o propulsión. Y el fabricante tendrá los datos en tiempo real de los miles o millones de sus creaciones girando, generando energía o moviendo cosas alrededor del mundo. Con estos datos, las empresas no sólo serán capaces de mantener las máquinas sin accidentes y pérdidas debido a la inactividad, sino que también podrían usar los datos para diseñar la próxima versión de la máquina con ventaja de conocer la totalidad de la historia de su ciclo de vida.

Iansiti y Lakhani (2014) establecen en su trabajo que adaptarse a la conectividad digital ubicua es esencial para competitividad en la mayoría de los sectores de la economía. Los autores refuerzan el concepto diciendo que han examinado la transformación en docenas de industrias y empresas, tanto tradicionales como digitales, y hablaron con cientos de ejecutivos en un esfuerzo por entender cómo los modelos tradicionales de la innovación y la ejecución operativa están cambiando.

Tienen visto que la transformación digital no es una disrupción tradicional. El paradigma no es el desplazamiento y reemplazo sino conectividad y recombinación.

El concepto de producto como servicio se ha ampliado a cualquier cosa como servicio (XaaS). Costa (2019) define que este concepto significa que, en lugar de ofrecer un producto como inversión o costo, se ofrece como un servicio pagando por lo que se usa reduciendo el costo de propiedad del equipo o máquina. En su artículo Costa (2019) sitúa a XaaS como el futuro de la economía colaborativa y da ejemplos más allá de Uber o Airbnb, como Mobike o BMW en china.

#### **4.3.4 Estrategia Lean 5.0, La optimización de procesos industriales en el marco del paradigma Industria 4.0**

En las últimas décadas, las empresas han trabajado para aumentar más la calidad y variedad de servicios y productos, así como minimizar costos y aumentar los beneficios, potenciando eficiencia de producción y procesos para los ciclos de vida del proyecto, y mejorar las condiciones de trabajo para las personas, y fidelización de los clientes (Mourtzis, D.,2016, y Hernandez-de-Menendez et al., 2020). En efecto, siempre se requiere que cualquier negocio sea exitoso y sostenible. Mientras que se buscan técnicas para la mejora continua.

Herramientas como la gestión Lean nos permiten mantener los resultados mientras somos capaces de competir en mercados muy volátiles (Smith y Besharov. 2019). El artículo de Ciano et al. (2019), pone de manifiesto el creciente interés en el vínculo entre Lean Management (LM) e I4.0, con el objetivo de eliminar el desperdicio de los procesos comerciales para mejorar su eficiencia, así como su competitividad según Lai et al. (2019). A pesar de la

existencia de documentos que combinan estos dos enfoques, no se visualiza una sistematización integral de conocimiento que estudia la interacción entre todos.

Por otro lado, la innovación abierta genera oportunidades para desarrollar soluciones tecnológicas encuadradas en el marco de I4.0, a partir de utilizar software o hardware libre, o metodologías colaborativas entre emprendedores, Universidades, y grandes empresas.

Un análisis bibliométrico preliminar en la base de datos Scopus, arrojó 240 documentos, con una evolución creciente del tipo exponencial. Se utilizó la siguiente consulta, ("Lean manufacturing" AND "Industry 4.0" OR "Lean 4.0")

Los primeros artículos sobre la materia se publicaron en el año 2016, 3 trabajos, y en el año 2021 se destacan 75 trabajos. El crecimiento exponencial de la temática, según se muestra en la figura 12, demuestra que el tema es de creciente interés en el ámbito de la comunidad académica.

Documents by year




Fig. 12. Cantidad de trabajos publicados por año sobre la temática LM e I4.0. Fuente: Scopus.

Por otro lado, el análisis también arrojó el porcentaje de documentos por área de investigación. Según se puede ver en la figura 13, Ingeniería, ciencia de decisiones, y gestión de negocios representan más del 50% de los artículos



publicados sobre el tema. Esto da otro indicador sobre lo pertinencia del tema para ser investigado, y generar conocimiento aplicado en la materia para transferir a las empresas locales.

#### Documents by subject area




Fig. 13. Distribución por área del conocimiento de los documentos publicados sobre LM e I4.0. Fuente: Scopus.

#### 4.3.5 IIoT y alternativas de arquitectura para integración de datos en la industria.

Tal como se adelantó en el capítulo 2, el tema las nuevas alternativas de arquitectura para integrar datos desde las operaciones hasta la función de planificación. Más allá del estándar ISA 95, citado en el capítulo 2, aparecen otros marcos de referencia como el RAMI 4.0 (Reference Architecture Model Industrie 4.0), desarrollado por la Asociación Alemana de Fabricantes Eléctricos y Electrónicos (ZVEI).

Por otro lado, la aparecen alternativas tecnológicas como la virtualización y la contenedorización para la gestión del sistema, que facilitan la integración de los sistemas OT en la seguridad de TI como una opción tecnológica para facilitar aún más la utilización de soluciones IIoT y llevar la OT a la nube.

Los temas enunciados en los párrafos anteriores, y el trabajo desarrollado en la tesis permiten abrir la puerta para continuar investigando y profundizar la temática de la IIoT y las numerosas alternativas que se generan para avanzar en la integración de los datos, y el agregado de valor a partir de modelos analíticos para la optimización de procesos industriales.

# REFERENCIAS

## Capítulo 1

A. Redchuk, and F. Walas Mateo (2022). New Business Models on Artificial Intelligence—the Case of the Optimization of a Blast Furnace in the Steel Industry by a Machine Learning Solution. *Applied System Innovation*. 5(1):6. <https://doi.org/10.3390/asi5010006>

W. Pfau, P. Rimpp. (2021). AI-Enhanced Business Models. *Digital Entrepreneurship, Digital Entrepreneurship, Future of 341 Business and Finance*. Springer International Publishing. [https://doi.org/10.1007/978-3-030-53914-6\\_7](https://doi.org/10.1007/978-3-030-53914-6_7)

V. L. Da Silva, J. Luiz Kovaleski, R. Negri Pagani, J. De Matos Silva, A. Corsi. (2019). Implementation of Industry 4.0 concept in companies: empirical evidences, *International Journal of Computer Integrated Manufacturing*.

UN General Assembly. “Transforming Our World: The 2030 Agenda for Sustainable Development” United Nations (UN), Oct. 2015.

J. Müller. European Commission, Directorate-General for Research and Innovation, Enabling Technologies for Industry 5.0: results of a workshop with Europe’s technology leaders, Publications Office, 2020, <https://data.europa.eu/doi/10.2777/082634>

F. Walas Mateo, A. Redchuk. (2022). Artificial Intelligence as a Process Optimization driver under industry 4.0 framework and the role of IIoT, a bibliometric analysis. – *Jiim. Journal of Industrial Integration and Management Innovation & Entrepreneurship*. ISSN (print): 2424-8622 | ISSN (online): 2424-8630. <https://doi.org/10.1142/S2424862222500130>

M. Di Nardo, H. Yu. (2021). Special Issue. Industry 5.0: The prelude to the sixth industrial revolution. *Appl. Syst. Innov*, 4, 45.

M. Doyle-Kent, P. Kopacek. (2020). Industry 5.0: Is the manufacturing industry on the cusp of a new revolution? *Adv. Mech. Eng.*, 432–441.

F. Walas Mateo, A. Redchuk, J. E. Tornillo. (2022). Industry 5.0 and new business models in mining. Adoption Case of Machine Learning to optimize the process at a copper Semi Autogenous Grinding (SAG) Mill. July 2022. 5th European IEOM Rome

B. Chander, S. Pal, D. De, R. Buyya. (2022). Artificial Intelligence-based Internet of Things for Industry 5.0. In: Pal, S., De, D., Buyya, R. (eds) *Artificial Intelligence-based Internet of Things Systems*. Internet of Things. Springer, Cham. [https://doi.org/10.1007/978-3-030-87059-1\\_1](https://doi.org/10.1007/978-3-030-87059-1_1)

M. Breque, L. De Nul, A. Petridis. (2021). European Commission, Directorate-General for Research and Innovation, Industry 5.0: towards a sustainable, human-centric and resilient European industry, Publications Office, <https://data.europa.eu/doi/10.2777/308407>.

P. K. Muhuri, K. Shukla, Amit, A. Abraham. (2019). Industry 4.0. A bibliometric analysis and detailed overview. *Eng. Appl. Artificial Intelligence* 78, 218–235.

D. Ibarra, J. Ganzaraina, J. I. Igartua. (2017). Business model innovation through Industry 4.0: A review. 11th International Conference

Interdisciplinarity in Engineering, INTER-ENG 2017, October 2017, Tirgu-Mures, Romania.

J. R. Ruiz-Sarmiento, J. Monroy, F. A. Moreno, C. Galindo, J. M. Bonelo, J. Gonzalez-Jimenez. (2020). A predictive model for the maintenance of industrial machinery in the context of industry. *Engineering Applications of Artificial Intelligence*. ISSN: 0952-1976.

F. Walas Mateo. (2020). Industry 4.0 and the emergence of new business models. LACCEI 2020. The Eighteen LACCEI International Multi-Conference For Engineering, Education Caribbean Conference For Engineering And Technology. Buenos Aires. Argentina.

F. Walas Mateo, A. Redchuk. (2021). The Emergence of New Business and Operating Models under the Industrial Digital Paradigm. *Industrial Internet of Things, Platforms, and Artificial Intelligence/Machine Learning*. International Conference of Production Research-Americas (ICPR-Americas). Editorial UNS. ISSN 2619-1865. Argentina.

J. Ganzarain, N. Errasti. (2016): Three stage maturity model in SME's toward industry 4.0, *Journal of Industrial Engineering and Management (JIEM)*, ISSN 2013-0953, OmniaScience, Barcelona, Vol. 9, Iss. 5, pp. 1119-1128.

F. Walas Mateo, A. Redchuk. (2021). Artificial Intelligence and Machine Learning as a Process Optimization driver under Industry 4.0 framework, the role of the people in the process. *Global Conference on Engineering Research (GLOBECER)*. Bandirma Onyedi Eylul University. 2-5 June 2021. Turkey. ISBN: 978-625-44365-9-8

P. Thiell. (2014). *De Cero a Uno*. Centro Libros PAPF, S.L.U, Grupo Planeta.

S. Erol, A. Schumacher, W. Sihn. (2016). Strategic guidance towards Industry 4.0 – a three-stage process model. *International Conference on Competitive Manufacturing 2016 (COMA'16)* at: Stellenbosch, South Africa

B. R. Ferrer, W. M. Mohammed, J. L. Martinez Lastra, A. Villalonga, G. Beruvides, F. Castaño, R. E. Haber. (2018). Towards the Adoption of Cyber-Physical Systems of Systems Paradigm in Smart Manufacturing Environments. *IEEE 16th International Conference on Industrial Informatics (INDIN)*. DOI: 10.1109/INDIN.2018.8472061.

A. Basco, G. Beliz, D. Coatz, P. Garnero. (2018). *industria 4.0: fabricando el futuro*. bid-intal-ua.

M. Casalet. (2018) "La digitalización industrial: un camino hacia la gobernanza colaborativa. Estudios de casos", *Documentos de Proyectos (LC/TS.2018/95)*, Santiago, Comisión Económica para América Latina y el Caribe (CEPAL).

C. Brixner, P. Isaak, S. Mochi, M. Ozono, G. Yoguel. (2019). *Industria 4.0: ¿intensificación del paradigma tic o nuevo paradigma tecno organizacional?* 1ª ed. - Ciudad Autónoma de Buenos Aires: ciecti,

J. Smit, S. Kreutzer, C. Moeller, M. Carlberg. (2016). *Industry 4.0*. Directorate General for Internal Policies. European Parliament. Disponible en: <http://www.europarl.europa.eu/studies> .

M. Wollschlaeger, T. Sauter, J. Jasperneite. (2017). The Future of Industrial Communication. Automation Networks in the Era of the Internet of Things and Industry 4.0. IEEE industrial electronics magazine, march 2017.

M. Porter, J. Heppelmann. (2015). How Smart, Connected Products Are Transforming Companies. Harvard Business Review.

F. Walas Mateo, A. Redchuk. (2021). A review of IIoT/IoT and AI/ML as Process Optimization driver under industry 4.0 model. Journal of Computer Science & Technology (JCS&T). Vol 21. ed. 2, pp 170-176.

F. Walas Mateo, A. Redchuk (2022). Process Optimization in the Steel Industry using Machine Learning adopting an Artificial Intelligence Low Code Platform. Jornadas de Cloud Computing, Big Data & Emerging Topics – 2022. DOI: 10.35537/10915/139373

A. Vazhnov. (2015). La Red de Todo, Internet de las Cosas y el Futuro de la Economía Conectada. @andreidigital

R. Dorf, A. Kusiak. (1994). Handbook of Design, Manufacturing and Automation. John Wiley & Sons Inc. Hoboken, Nueva Jersey, Estados Unidos.

OECD (2020), Digitalisation and Responsible Business Conduct: Stocktaking of policies and initiatives. Centre for Responsible Business Conduct. OEDC.

R. G. Cooper, A. F. Sommer. (2018). Agile–Stage-Gate for Manufacturers: Changing the Way New Products Are Developed’, Research-Technology Management, 61(2), pp. 17–26.

D. G. Ullman. (2019). Scrum for Hardware Design. Oregon: David Ullman LLC.

A. Di Minin, C. De Marco, C. Marullo, A. Piccaluga, E. Casprini, M. Mahdad, A. Paraboschi. (2016) 'Case Studies on Open Innovation in ICT'; Institute for Prospective Technological Studies, Joint Research Centre. JRC Science for Policy Report.

H.W. Chesbrough. (2003). The era of open innovation. MIT Sloan Management Review.

E. von Hippel. (1998). THE SOURCES OF INNOVATION. New York Oxford University Press

E. von Hippel. (2005). Democratizing innovation: The evolving phenomenon of user innovation. JfB 55, 63–78. <https://doi.org/10.1007/s11301-004-0002-8>

Sitio web de ODOO. Disponible online: <https://www.odoo.com/> (accedido el 15 de mayo de 2022).

M. Iansiti, K. Lakhani. (2020). Competing in the age of AI: strategy and leadership when algorithms and networks run the world / Boston, MA: Harvard Business Review Press.

E. Ries. (2011). The Lean Startup. Crown Business (USA). ISBN 0307887898

## **Capítulo 2**

W. He, L. Xu. (2014). Integration of Distributed Enterprise Applications: A Survey. IEEE Transactions on Industry Informatics, 10(1), pp. 35-42.

- ISA. International Society of Automation. Available online: <https://www.isa.org/> (accessed on 1 July 2022).
- International Electrotechnical Commission. Available online: <https://www.iec.ch/> (accessed on 1 July 2022).
- American National Standards Institute (ANSI), ISA-95.00.01-2010, ISA-95.00.02-2010, ISA-95.00.03-2013, ISA-95.00.04-2012, ISA-95.00.05-2013. North Carolina USA.
- M. Åkerman. (2018). Implementing Shop Floor IT for Industry 4.0. Department of Industrial and Materials Science. CHALMERS UNIVERSITY OF TECHNOLOGY. Gothenburg, ISBN 978-91-7597-752-2.
- A. Seetharaman, N. Patwa, A.S. Saravanan, A. Sharma. (2019). Customer expectation from Industrial Internet of Things (IIOT). *Journal of Manufacturing Technology Management*.
- B. Chandler, S. Pal, D. De, R. Buyya. (2022). Artificial Intelligence-based Internet of Things for Industry 5.0. *Artificial Intelligence-based Internet of Things Systems*. DOI: 10.1007/978-3-030-87059-1\_1
- A. Garbugli, A. Bujari, P. Bellavista. (2021). End-to-end QoS Management in Self-Configuring TSN Networks. In *Proceedings of the IEEE International Conference on Factory Communication Systems (WFCS)*, Linz, Austria, 9–11 June 2021; pp. 131–134. [CrossRef]
- A. Arestova, M. Martin, K.S.J. Hielscher, R. German. (2021). A Service-Oriented Real-Time Communication Scheme for AUTOSAR Adaptive Using OPC UA and Time-Sensitive Networking. *Sensors* 2021, 21, 2337. [CrossRef]
- L. Patera, A. Garbugli, A. Bujari, D. Scotece, A. Corradi. A Layered Middleware for OT/IT Convergence to Empower Industry 5.0 Applications. *Sensors* 2022, 22, 190. <https://doi.org/10.3390/s22010190>
- P. Lara, M. Sánchez, J. Villalobos. (2020). Enterprise modelling and operational technologies (OT) application in the oil and gas industry. *Journal of Industrial Information Integration*.
- F. Walas Mateo, A. Redchuk. (2021). A review of IIoT/IoT and AI/ML as Process Optimization driver under industry 4.0 model. *Journal of Computer Science & Technology (JCS&T)*. Vol 21. ed. 2, pp 170-176. <https://doi.org/10.24215/16666038.21.e15>
- E. Yalcinkaya, A. Maffei, H. Akillioglu, M. Onori. (2021). Empowering ISA95 compliant traditional and smart manufacturing systems with the blockchain technology. *Manufacturing Review*. 8, 15 <https://doi.org/10.1051/mfreview/2021013>.
- G.D.N. Silveira, R. F. Viana, M.J. Lima, H.C. Kuhn, C.D.P. Crovato, S.B. Ferreira, G. Pesenti, E. Storck, R. da Rosa Righ. (2020). I4.0 pilot project on a semiconductor industry: Implementation and lessons learned. *Sensors* 2020, 5752S.
- S. Yang, P. Navarathna, S. Ghosh, B.W. Bequette. (2020). Hybrid Modelling in the Era of Smart Manufacturing. *Computers and Chemical Engineering*. DOI: 10.1016/j.compchemeng.2020.106874.

- J. Vater, L. Harscheidt, A. Knoll. (2019). Smart Manufacturing with Prescriptive Analytics. Proceedings of 2019 8th International Conference on Industrial Technology and Management, ICITM.
- M. Khakifirooz, C.F. Chien, Y.J. Chen. (2018). Bayesian inference for mining semiconductor manufacturing big data for yield enhancement and smart production to empower industry 4.0. Applied Soft Computing Journal.
- I. Erozan. (2019). A fuzzy decision support system for managing maintenance activities of critical components in manufacturing systems. Journal of Manufacturing Systems. June 2019.
- Z. Kang, C. Catal, B. Tekinerdogan. (2020). Machine learning applications in production lines: A systematic literature review. Computers & Industrial Engineering 149. Tayal et al., 2020
- M. Javaid, A. Haleem, R.P. Singh, R. Suman. (2022). Artificial intelligence applications for industry 4.0: A literature-based study. Journal of Industrial Integration and Management, 7(01), 83-111.
- A. Jamwal, R. Agrawal, M. Sharma, A. Giallanza. (2021). Industry 4.0 Technologies for Manufacturing Sustainability: A Systematic Review and Future Research Directions. Appl. Sci. 2021, 11, 5725.  
<https://doi.org/10.3390/app11125725>
- C. Gonçalves Machado, M.P. Winroth, E.H. Dener Ribeiro da Silva. (2020). Sustainable manufacturing in Industry 4.0: an emerging research agenda, International Journal of Production Research, 58:5, 1462-1484, DOI: 10.1080/00207543.2019.1652777.
- M. Khan, X. Wu, X. Xu and W. Dou, "Big data challenges and opportunities in the hype of Industry 4.0," 2017 IEEE International Conference on Communications (ICC), Paris, France, 2017, pp. 1-6, doi: 10.1109/ICC.2017.7996801.
- R. Kumar, S. Prakash Singh, K. Lamba. (2018). Sustainable robust layout using Big Data approach: A key towards industry 4.0. Journal of Cleaner Production, Volume 204, Pages 643-659, ISSN 0959-6526,  
<https://doi.org/10.1016/j.jclepro.2018.08.327>.
- M. Sharp, R. Ak, T. Hedberg (2018). A survey of the advancing use and development of machine learning in smart manufacturing. Journal of Manufacturing Systems. Volume 48, Part C, Pages 170-179, ISSN 0278-6125,  
<https://doi.org/10.1016/j.jmsy.2018.02.004>.
- J. Hernández Orallo; M.J. Ramírez Quintana; C. Ferri Ramírez. (2004). Introducción a la Minería de Datos. Pearson Educación SA. Madrid. ISBN 84-205-4091-9
- R. Sharma, S. S. Kamble, A. Gunasekaran, V. Kumar, A. Kumar. (2020). A systematic literature review on machine learning applications for sustainable agriculture supply chain performance. Computers & Operations Research. Volume 119, 104926, ISSN 0305-0548,  
<https://doi.org/10.1016/j.cor.2020.104926>.
- M. Syafrudin, G. Alfian, N.L. Fitriyani, J. Rhee. (2018). Performance Analysis of IoT-Based Sensor, Big Data Processing, and Machine Learning Model for Real-

Time Monitoring System in Automotive Manufacturing. *Sensors* 2018, 18, 2946. <https://doi.org/10.3390/s18092946>

J.L. Loyer, E. Henriques, M. Fontul, S. Wiseall. (2016). Comparison of Machine Learning methods applied to the estimation of manufacturing cost of jet engine components, *International Journal of Production Economics*, Volume 178, Pages 109-119, ISSN 0925-5273, <https://doi.org/10.1016/j.ijpe.2016.05.006>.

P. Priore, D. de la Fuente, R. Pino. (2001). Learning-based scheduling of flexible manufacturing systems using case-based reasoning, *Applied Artificial Intelligence*, 15:10, 949-963, DOI: 10.1080/088395101753242697.

G. Pedone, I. Mezgár. (2018). Model similarity evidence and interoperability affinity in cloud-ready Industry 4.0 technologies. *Computers in Industry*. Vol. 100 (2018) 278-286.

I. Witten, E. Frank, M. A. Hall, C.J. Pal. (2017). *Data Mining. Practical Machine Learning Tools and Techniques*. Fourth Edition. Morgan Kaufmann, Elsevier. Cambridge, MA 02139, United States. ISBN: 978-0-12-804291-5L.

L. Brun, G. Gereffi, J. Zhan. (2019). The “lightness” of Industry 4.0 lead firms: implications for global value chains. In *Book Transforming Industrial Policy for the Digital Age: Production, Territories and Structural Change*. Publisher: Edward Elgar Publishing Ltd.

R. Mishra, A. Gandhi, R. Jaiswal, S. Mishra, A. Fadnis. (2018). Machine Learning to Improve Blast Furnace Productivity at Jindal Steel & Power. In *Proceedings of the AISTech 2020, Iron & Steel Technology Conference*, Cleveland, OH, USA, 31 August–3 September 2020. Spadaccini et al.

P.E. Gazola, O. dos Santos HS, M. Daroit, A.A. Locatelli. (2020). Machine Learning Approach for Steel Grade Detection in Hot Rolling Mills. In *Proceedings of the AISTech 2021, Iron & Steel Technology Conference*, Nashville, TN, USA, 29 June–1 July 2020.

C. Waters, B. Klemme, R. Talla, P. Jain, N. Mehta. (2021). Transforming Metal Production by Maximizing Revenue Generation With Operational AI. In *Proceedings of the AISTech 2021, Iron & Steel Technology Conference*, Nashville, TN, USA, 29 June–1 July 2021

V. Manojlović, Ž. Kamberović, M. Korać, M. Dotlić. (2022). Machine learning analysis of electric arc furnace process for the evaluation of energy efficiency parameters, *Applied Energy* 307 118209 (2022). DOI: 10.1016/j.apenergy.2021.118209.

S. Avalos, W. Kracht, J.M. Ortiz. (2021). Machine Learning and Deep Learning Methods in Mining Operations: A Data-Driven SAG Mill Energy Consumption Prediction Application. *Mining, Metallurgy & Exploration*. 37:1197-1212. <https://doi.org/10.1007/s42461-020-00238-1>

V. Flores, C.A. Leiva. (2021). Comparative Study on Supervised Machine Learning Algorithms for Copper Recovery Quality Prediction in a Leaching Process. *Sensors* 2021, 21, 2119. <https://doi.org/10.3390/s21062119>.

L. Barnerwold, B.G. Lotermozzer. (2020). Identification of digital technologies and digitalisation trends in the mining industry. *International Journal of Mining Science and Technology*. Volume 30, Issue 6, November 2020, Pages 747-757



S. Zelinska. (2020). Machine learning: technologies and potential application at mining companies. E3S Web of Conferences 166, 03007 (2020) <https://doi.org/10.1051/e3sconf/202016603007>

D. Ali, S. Fripong. (2020). Artificial Intelligence, machine learning and process automation: existing knowledge frontier and way forward for mining sector. Artificial Intelligence Review (2020) 53:6025-6042 <https://doi.org/10.1007/s10462-020-09841-6>

W.F. Visser. (2020). A Blueprint for Performance-Driven Operations Management. Mining, Metallurgy & Exploration 37:823-831. <https://doi.org/10.1007/s42461-020-00199-5>

N.R. Sharma, A.K. Mishra, S. Jain. (2021). Impact factor improvement and maintenance Schedule optimization of mining shovels by remaining useful life and linear programming. Journal of Mines, Metals and Fuels. Volume 69, Issue 9, Pages 315 - 326. September 2021.

H. Abukwaik, L. Sula, P. Rodriguez. (2022). TopSelect: A Topology-based Feature Selection Method for Industrial Machine Learning. Proceedings - 1st International Conference on AI Engineering - Software Engineering for AI, CAIN 2022, 46,47. 10.1145/3522664.3528618.

T. H. Davenport. (2020). Is AI Getting easier? Forbes Media LLC.

Y. Lin, A. M. Shahhosseini, M. A. Badar, T. Foster, J. Dean. (2016). A concept map-based cognitive framework for acquiring expert knowledge in industrial environment. Proceedings - Frontiers in Education Conference, FIE Volume 2016. Article number 775770246th Annual Frontiers in Education Conference.

### **Capítulo 3**

F. Walas Mateo, A. Redchuk. (2021). The Emergence of New Business and Operating Models under the Industrial Digital Paradigm. Industrial Internet of Things, Platforms, and Artificial Intelligence/Machine Learning. Journal of Mechanics Engineering and Automation 11 54-60 doi: 10.17265/2159-5275/2021.02.004.

F. Walas Mateo, A. Redchuk. (2022). Artificial Intelligence as a Process Optimization driver under industry 4.0 framework and the role of IIoT, a bibliometric analysis. – JIIM. Journal of Industrial Integration and Management. DOI: 10.24215/16666038.21.e15

A. Osterwalder, Y. Pigneur, C.L. Tucci. (2005). Clarifying Business Models: Origins, Present, and Future of the Concept. Communications of the Association for Information Systems, 16, pp-pp. <https://doi.org/10.17705/1CAIS.01601>.

M. Borja. (2020). La Doble velocidad de los datos: Como incorporar una estrategia “Data Driven” en la organización. Harvard Deusto. Feb. 2020.

M. Iansiti, K. Lakhani. (2014). Digital Ubiquity: How Connections, Sensors, and Data Are Revolutionizing Business. Harvard Business Review. Nov. 2014.

F. Walas Mateo, A. Redchuk. (2020). The Emergence of New Business and Operating Models under the Industrial Digital Paradigm. Industrial Internet of Things, Platforms, and Artificial Intelligence/Machine Learning. International

Conference of Production Research-Americas (ICPR-Americas). Editorial UNS. ISSN 2619-1865.

D. C. Cozmiuc, I. I. Petrisor. (2018). Handbook of Research on Strategic Innovation Management for Improved Competitive Advantage Volume 2, Pages 477-497 Innovation in the age of digital disruption: The case of Siemens (Book Chapter). 13 April 2018.

P. Sailer, B. Stutzmann, D. Kobold. (2019). Successful Digital Transformation. How Change Management helps you to hold course. Siemens IoT Services. Copyright © Siemens AG. Oct 2019

D. Di Ruscio, D. Kolovos, J. Lara, A. Pierantonio, M. Tisi, M. Wimmer. (2022). Low-code development and model-driven engineering: Two sides of the same coin? *Software and Systems Modeling* (2022) 21:437–446 <https://doi.org/10.1007/s10270-021-00970-2>.

C. Richardson, J.R. Rymer. (2014). *New Development Platforms Emerge For Customer-Facing Applications*; Forrester: Cambridge, MA, USA, 2014.

R. Waszkowski. (2019). Low-code platform for automating business processes in manufacturing. *IFAC-PapersOnLine*. IFAC-PapersOnLine. Volume 52, Issue 10, 2019, Pages 376-381. doi.org/10.1016/j.ifacol.2019.10.060

A.C. Bock, U. Frank. (2021). Low-Code Platform. *Business & Information Systems Engineering* 63(3–4). DOI: 10.1007/s12599-021-00726-8

J. Cabot. (2020). Positioning of the low-code movement within the field of model-driven engineering. In *Proceedings of the MODELS'20: ACM/IEEE 23rd International Conference on Model Driven Engineering Languages and Systems*, Virtual Event, Canada, 18–23 October 2020.

R. Sanchis, O. García-Perales, F. Fraile, R. Poler. (2020). Low-Code as Enabler of Digital Transformation in Manufacturing Industry. *Appl. Sci.* 2020, 10, 12. <https://doi.org/10.3390/app10010012>

Sitio web de Azure. (2022). disponible online: <https://azure.microsoft.com/> (accedido el 22 julio de 2022).

G. Schuh, T. Gartzena, S. Soucy-Bouchardb, F. Basse. (2017). 'Enabling Agility in Product Development through an Adaptive Engineering Change Management', *Procedia CIRP*, 63, pp. 342–347.

E.C. Conforto, F. Salum, D.C. Amaral, S. L. da Silva, L. F. Magnanini de Almeida. (2014). Can Agile Project Management Be Adopted by Industries Other than Software Development? *Project Management Journal*, 45(3), pp. 21–34.

P. Diebold, M. Dahlem. (2014). Agile practices in practice. *Proceedings of the 18th International Conference on Evaluation and Assessment in Software Engineering - EASE '14*. London, UK: ACM Press, pp. 1–10.

G. Schuh, M. Riesener, F. Diels. (2016). Structuring highly iterative product development projects by Using HIP-indicators. *IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*. Bali, Indonesia: IEEE, pp. 1171–1175.

G. Kumar, P.K. Bhatia. (2012). Impact of Agile Methodology on Software Development Process. *International Journal of Computer Technology and Electronics Engineering (IJCTEE)*, 2(4), pp. 46–50

- T. Thesing, C. Feldmann, M. Burchardt. (2021). Agile versus Waterfall Project Management: Decision Model for Selecting the Appropriate Approach to a Project. *Procedia Computer Science*, 181, pp. 746–756.
- R. G. Cooper. (2016). Agile–Stage-Gate Hybrids: The Next Stage for Product Development, *Research-Technology Management*, 59(1), pp. 21–29.
- R. G. Cooper, A. F. Sommer. (2018). The Agile-Stage-Gate Hybrid Model: A Promising New Approach and a New Research Opportunity. *Journal of Product Innovation Management*, 33(5), 513-526. <https://doi.org/10.1111/jpim.12314>
- A. Atzberger, K. Paetzold. (2019). Current challenges of agile hardware development: What are still the pain points nowadays? *Proceedings of the International Conference on Engineering Design, ICED*. Delft, Netherlands: Cambridge University Press, pp. 2209–2218.
- D. G. Ullman. (2019). *Scrum for Hardware Design*. Oregon: David Ullman LLC.
- K. Edwards, R.G. Cooper, T. Vedsmand, G. Nardelli. (2019). Evaluating the agile-stage-gate hybrid model: Experiences from three SME manufacturing firms. *International Journal of Innovation and Technology Management*, 16(8), pp. 1–31.
- P.G. Mota, A.L.B. de Silva, R.F.C. Limongi. (2022). The use of agile methodologies and their contribution to innovation of the business model: a study of multiple cases in the context of incubators and startups. *Iberoamerican Journal of Entrepreneurship and Small Business*, 11(2), Article e2170. <https://doi.org/10.14211/ibjesb.e2170>
- J. A. Faiña Medín, C. Losada-López, P. Montes-Solla. (2016). Innovación y emprendedurismo: Ordenando el rompecabezas de la Nueva Gestión Empresarial de la Innovación [Innovation and entrepreneurship: Sorting the puzzle of the New Business Management of Innov," MPRA Paper 75479, University Library of Munich, Germany.
- S. Blank (2013). Why the Lean Startup changes everything. *Harvard Business Review*, May 2013
- W. R. Kerr, R. Nanda, M. Rhodes-Krop. (2014). *Journal of Economic Perspectives*. Volume 28, Number 3, 2014. Pages 25–48. DOI: 10.1257/jep.28.3.25.
- F. Scheuenstuhl, P. Bican, A. Brem. (2021). How Can the Lean Startup Approach Improve the Innovation Process of Established Companies? An Experimental Approach. *International Journal of Innovation Management* 2150029 © World Scientific Publishing Europe Ltd. DOI: 10.1142/S136391962150029P.
- Daoutidis, J.H. Lee, I. Harjunkoski, S. Skogestad, M. Baldea, C. Georgakis. Integrating operations and control: A perspective and roadmap for future research. *Computers & Chemical Engineering*, Volume 115,179-184, ISSN 0098-1354,
- R. Mishra, A. Gandhi, R. Jaiswal, S. Mishra, A. Fadnis. (2020). Machine Learning to Improve Blast Furnace Productivity at Jindal Steel & Power. In *Proceedings of the AISTech 2020, Iron & Steel Technology Conference*, Cleveland, OH, USA, 31 August–3 September 2020.

K. Nishioka, Y. Ujisawa, K. Akatani. (2018). Development of Mathematical Models for Blast Furnaces. Nippon Steel Sumitomo Met. Tech. Rep. 2018, 120, 69–75.

Website de OSIsoft. (2021). Disponible en: [www.osisoft.com](http://www.osisoft.com) (accedido el 26 de julio 2021).

C. Chelgani, H. Nasiri, A. Tohry. (2021). Modelling of particle sizes for industrial HPGR products by a unique explainable AI tool- A “Conscious Lab” development. *Advanced Powder Technology* 32 (2021) 4141–4148

#### **Capítulo 4**

J. Cotta, M. Breque, L. De Nul, A. Petridis. (2020). Towards a sustainable, human-centric and resilient European industry. Online DOI: <https://op.europa.eu/publication-detail-publication/468a892a-5097-11eb-b59f-01aa75ed71a1>CSO. CSO Online: <https://www.cso.ieenrel>.

G. Costa. (2016). El Futuro de la Economía colaborativa. *Harvard Business Deusto*. Oct. 2019.

D. Mourtzis. (2016). Challenges and future perspectives for the life cycle of manufacturing networks in the mass customisation era. *Logistic Research*. 9, 2. Doi.org/10.1007/s12159-015-0129-0

Hernandez-de-Menendez, M., Díaz, C.A.E., Morales-Menendez, R. (2020). Engineering education for smart 4.0 technology: a review. *International Journal on Interactive Design and Manufacturing (IJIDeM)*. 14, 789–803.

W.K. Smith, M.L. Besharov. (2019). Bowing before dual gods: How structured flexibility sustains organizational hybridity. *Administrative Science Quarterly*. 64, 1–44.

M.P. Ciano, R. Pozzi, T. Rossi, F. Strozzi. (2019). How IJPR has addressed ‘lean’: a literature review using bibliometric tools. *Int. J. Prod. Res.* 57, 5284–5317

G. N. Y. Lai, K.H. Wong, D. Halim, J. Lu, H.S. Kang. (2019) Industry 4.0 enhanced lean manufacturing. In: 8th International Conference on Industrial Technology and Management, ICITM 2019, 2-4 March 2019, Cambridge, United Kingdom.