

MEMORIA ANUAL 2020

CÁTEDRA
DE INDUSTRIA
CONECTADA



ABB



endesa

Gestamp 

IBM

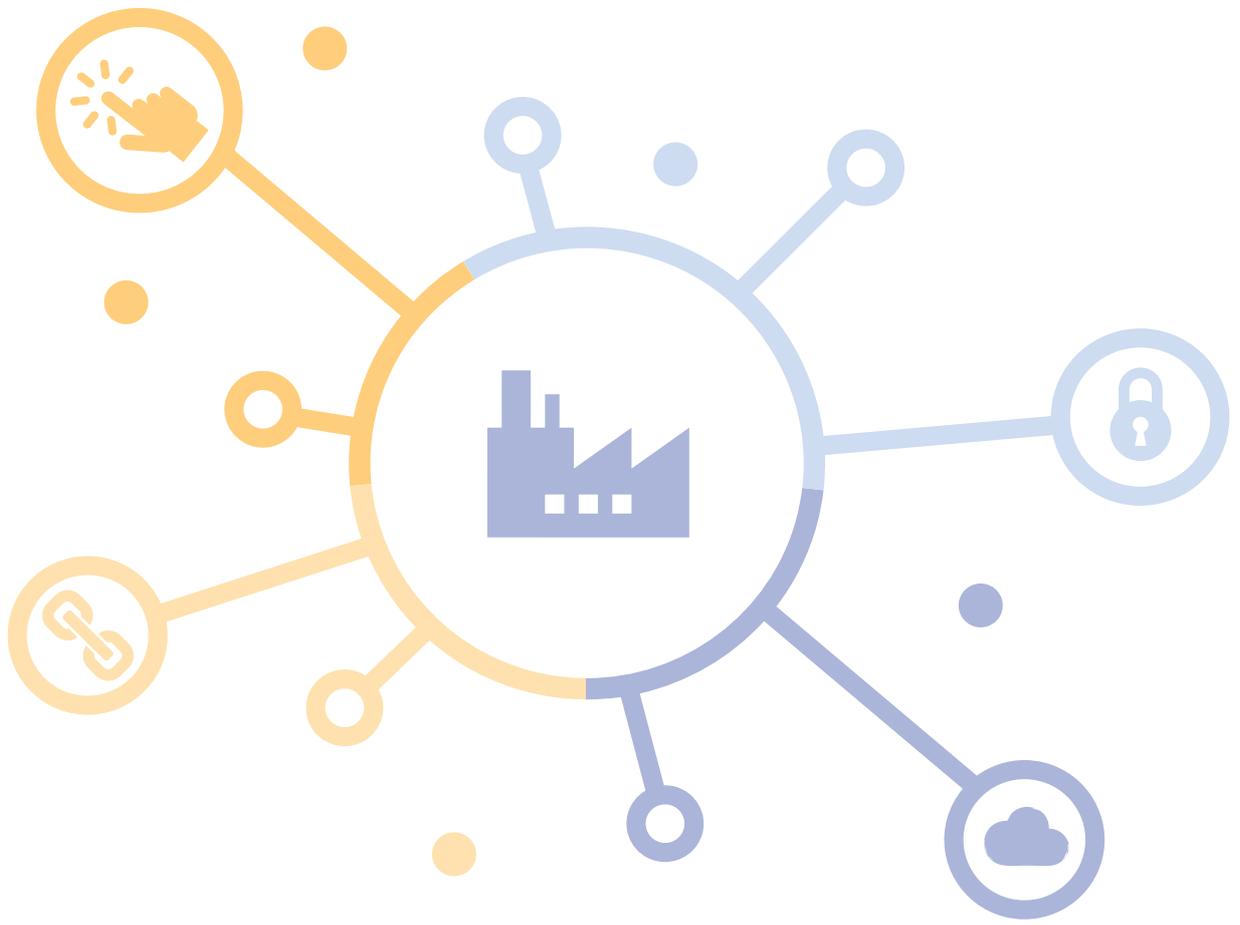
indra

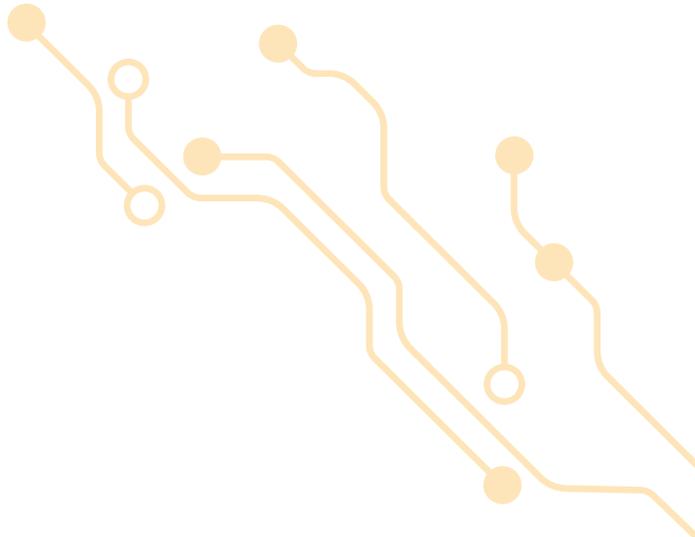


 PROSEGUR



 **SaarGummi**
Automotive





MEMORIA ANUAL 2020

**CÁTEDRA
DE INDUSTRIA
CONECTADA**





CARTA DE LOS DIRECTORES

Queridos amigos de la Cátedra,

La Cátedra de Industria Conectada de la Escuela Técnica Superior de Ingeniería (ICAI) ha cumplido su cuarto año, un ejercicio que ha estado marcado por la pandemia de la Covid-19. Todos, administraciones públicas, empresas, universidades y ciudadanos, hemos tenido que afrontar un año lleno de dificultades y adaptarnos rápidamente con altas dosis de esfuerzo, flexibilidad y resiliencia.

En la Cátedra, con la estrecha colaboración de las doce empresas patrono, hemos tratado de mantener el rumbo, adaptando las formas de trabajo, para seguir cumpliendo con nuestra misión de ayudar a la industria española a aprovechar las oportunidades generadas por la 4ª revolución industrial. En marzo pasamos a formato virtual nuestros tradicionales “Desayunos con CEOs”, así como todas las actividades formativas del Doble Máster en Ingeniería Industrial e Industria Conectada y del Programa Avanzado en Industria Conectada. Liderazgo y Transformación Digital. También celebramos el “IV Hackathon for Smart Industry” junto con Prosegur en un formato no presencial. Todos hemos visto como la tecnología, en particular la conectividad, ha sido esencial para mantener la continuidad de las actividades.

El CIC LAB, nuestro laboratorio de investigación e innovación, se ha consolidado con la participación durante todo el año de 30 estudiantes que han estado buscando soluciones a los problemas planteados por algunas de las empresas patrono. Ha sido un reto trabajar y coordinar los equipos en remoto, pero los resultados obtenidos confirman el éxito de esta iniciativa tanto por la experiencia formativa que supone para los estudiantes como por las soluciones ofrecidas a los patronos.

Este año también adaptamos la agenda e incluimos actividades centradas en la pandemia. Tuvimos sesiones privadas con los patronos para analizar el impacto de la Covid-19 en la industria, en las cadenas de suministro y en las formas de trabajar. En una sesión abierta al público invitamos a Tomás Pueyo, ingeniero del ICAI, que en abril de 2020 se convirtió de forma súbita en una de las personas más influyentes a escala mundial en la lucha contra la pandemia por su artículo “*The Hammer and the Dance*”. Finalmente, en noviembre cerramos el año con el ciclo “La persona en el centro”, en el que en cuatro sesiones participaron los CEOs de las empresas patrono junto con Raúl Blanco, Secretario General de Industria y PYME, y Carme Artigas, Secretaria de Estado de Digitalización e Inteligencia Artificial.

En 2021 queremos seguir avanzado en la consecución de nuestros objetivos y por ello estamos impulsando y apoyando nuevos programas de grado y postgrado de ICAI en el ámbito de la digitalización de la industria y en inteligencia artificial. Seguiremos resolviendo retos en el CIC LAB, organizando los desayunos con los CEOs más influyentes, y debatiendo sobre los temas de más impacto en las jornadas públicas y en las sesiones de trabajo privadas con los patronos. También nos esforzaremos en aprovechar la oportunidad que suponen los fondos de recuperación *Next Generation* para las empresas patrono y para la universidad.

El año 2021 se presenta lleno de incertidumbre fruto de las consecuencias económicas y sociales de la pandemia, pero nosotros lo vemos lleno de oportunidades que queremos seguir compartiendo con vosotros.

Mariano Ventosa

Vicerrector de Investigación e Internacionalización, Codirector de la Cátedra

Bernardo Villazán

Presidente Observatorio Industria 4.0, Codirector de la Cátedra

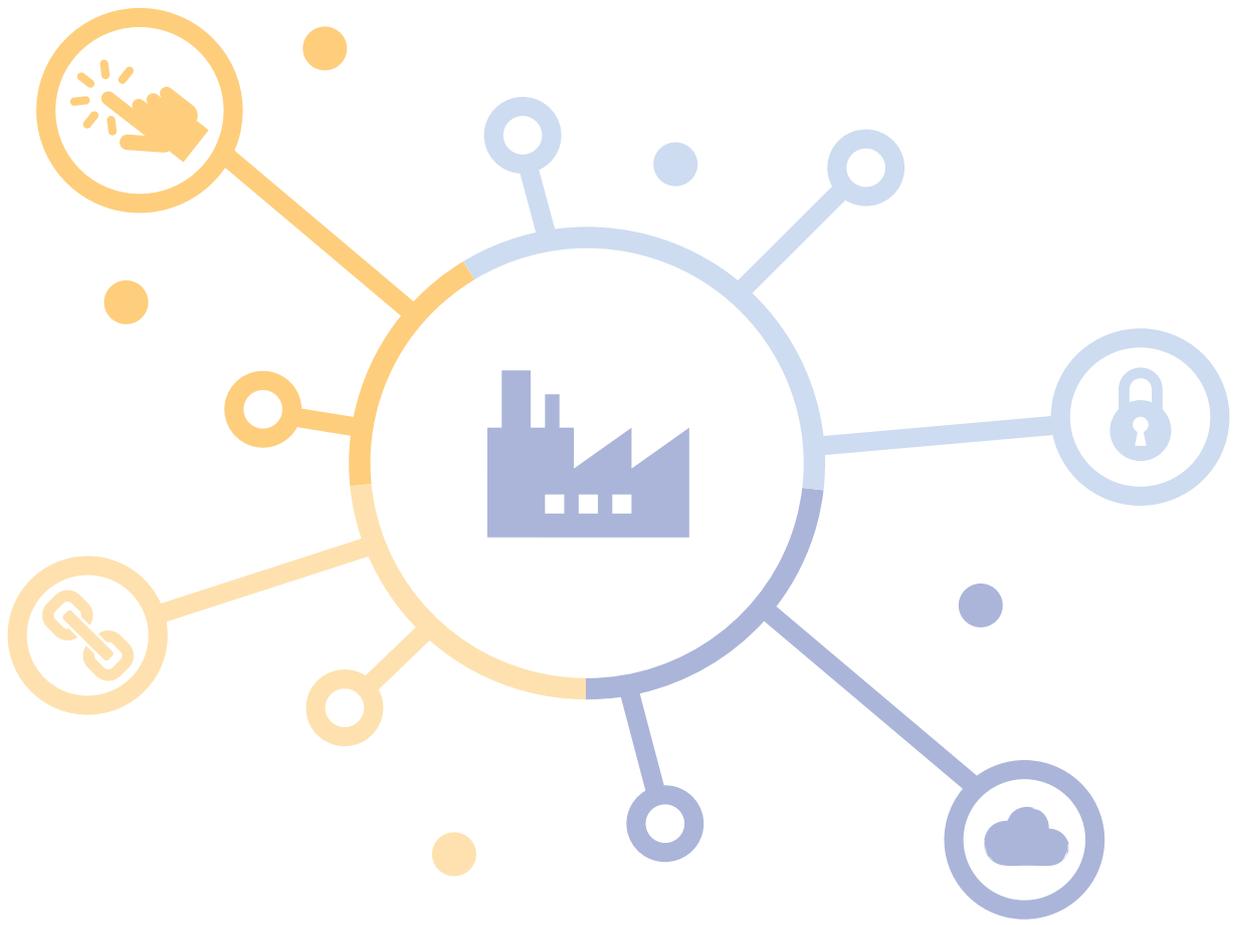


TABLA DE CONTENIDO

▶ Carta de los Directores	5
▶ Tabla de contenido	7
▶ Eventos Públicos	9
1. EL PAPEL CLAVE DE LAS TIC EN LA CRISIS GLOBAL – 2 de abril	10
2. HACER VISIBLE LO INVISIBLE – 2 de julio	12
3. LA PERSONA EN EL CENTRO – 3, 10, 17 y 24 de noviembre	14
▶ IV Hackathon for Smart Industry 20 y 21 de noviembre	21
▶ Desayunos con CEO	25
1. JESÚS SÁNCHEZ-QUIÑONES, CEO de Renta4 – 7 de mayo	26
2. JUAN DE NAVASCUÉS, CEO de SaarGummi – 2 de julio	27
3. EZEQUIEL SZAFIR, CEO de Openbank – 13 de julio	28
4. MARÍA HELENA ANTOLIN, Vicepresidenta de Grupo Antolin – 10 de septiembre	30
▶ Investigación	33
1. La edición del CIC LAB del verano de 2020	34
• Optimización de almacén – SaarGummi	35
• Visión artificial – Prosegur	43
• Destreza Robótica – Grupo Antolln	62
• Trading en mercados de commodities – Repsol	72
• IloT en entornos ATEX – Repsol	73
• Analítica avanzada en la red de distribución – Endesa	82
• Ciberseguridad industrial – Endesa	94
2. Estado actual de las líneas de investigación	103
▶ Formación	105
1. Doble Máster Universitario en Ingeniería Industrial e Industria Conectada (MI-MIC)	106
2. Programa Avanzado en Industria Conectada. Liderazgo y Transformación Digital	110



EVENTOS PÚBLICOS

Uno de los objetivos principales de la Cátedra es contribuir a que la industria española aproveche las oportunidades generadas por la cuarta revolución industrial. Consciente de ello, la Cátedra ha continuado organizando sus ya tradicionales **jornadas temáticas abiertas al público** con la finalidad de generar un espacio de reflexión y debate para analizar cuestiones clave para la Industria 4.0.

En respuesta a la crisis global vivida en este 2020, hemos llevado estos encuentros abiertos al público al formato online, finalizando el año con un ciclo de eventos en formato híbrido presencial-online.

Como no podía ser de otra forma, las temáticas de los eventos de este año han estado fuertemente ligadas a la pandemia que hemos vivido. Comenzamos el año debatiendo sobre el papel de las TIC en la crisis global, luego reflexionamos sobre los distintos escenarios y desafíos planteados en la "nueva normalidad" y en el futuro próximo; y compartimos las experiencias de distintas empresas industriales y tecnológicas, situando siempre a la persona en el centro de nuestros debates.

Estos eventos atraen a un número elevado de participantes ya que constituyen un punto de encuentro entre profesionales de las empresas patrono y otras empresas españolas, expertos en las temáticas abordadas y alumnos interesados en ampliar sus conocimientos.

1. EL PAPEL CLAVE DE LAS TIC EN LA CRISIS GLOBAL



2 DE ABRIL

FORMATO
ONLINE



En la actual crisis provocada por la Covid-19, y con las medidas excepcionales de confinamiento adoptadas, las telecomunicaciones y los sistemas y tecnologías de información constituyen un elemento esencial y crítico en nuestra actividad.

Por tal motivo, la Cátedra de Industria Conectada celebró su primer evento público en formato online el pasado 2 de abril del 2020, adaptándose a la situación sanitaria y buscando generar un espacio de reflexión sobre la misma.

En esta oportunidad, varios expertos ofrecieron las claves que aportan las tecnologías de información y comunicaciones en situaciones de crisis global.

La sesión se celebró en directo y contó con la participación de **Marta Martínez Alonso**, presidenta general de IBM para Europa; **José Antonio López Muñoz**, CEO de Ericsson España y **Carlos Grau**, CEO de Mobile World Capital Barcelona.

Durante este encuentro virtual se debatieron cuestiones como la preparación para situaciones de crisis globales, cómo ayudan las TIC a mitigar los riesgos y qué se espera del futuro 5G y la computación cuántica.



Marta Martínez Alonso,
presidenta general de IBM
para Europa



José Antonio López
Muñoz, CEO de Ericsson
España



Carlos Grau,
CEO de Mobile World
Capital Barcelona

Si te lo perdiste puedes acceder a la conferencia completa en este enlace:



<https://www.conversaciones40.com/video/el-papel-clave-de-las-tic-en-la-crisis-global/4123#>

2. HACER VISIBLE LO INVISIBLE



2 DE JULIO

FORMATO
ONLINE



El 2020 nos trasladó a un escenario de “nueva normalidad”, en el que conviven las experiencias en confinamiento, con la expansión de la pandemia, y los efectos de las muy diversas medidas que en cada país se han adoptado. Es necesario contar con diferentes voces que nos ayuden a convertir datos en información veraz, compartir, decidir, y actuar. Contribuir a hacer visible, un enemigo invisible, entender qué más podemos hacer, con esperanza y determinación.

En este segundo evento público del 2020, celebrado el 2 de julio de forma online, intentamos dar respuesta a las siguientes interrogantes:

¿Qué podemos esperar a partir de ahora? ¿Cómo debemos actuar?

Para ello, contamos con la participación especial de **Tomás Pueyo Brochard**, una de las voces más influyentes sobre el Covid-19. Ingeniero de Comillas ICAI, actualmente trabajando en Silicon Valley, quien se convirtió en una referencia global tras la publicación de su artículo “El martillo y la danza”, que en pocos días fue leído por millones de personas a nivel mundial y resultó determinante en las decisiones de muchos gobiernos.



Tomás Pueyo Brochard,
ingeniero de ICAI, autor de
"El martillo y la danza"



Juan Antonio Garrigosa de
Sigmaringa, Head of Business to
Government (B2G) de ENDESA X



José Daniel García Espinel
Innovation Director PGA,
PROSEGUR

Por otro lado, contamos con una mesa redonda para debatir sobre los procesos de innovación abierta en las empresas y de qué manera los mismos contribuyen a la sociedad.

En la causa común de la lucha contra el Covid-19, grandes empresas están contribuyendo desde sus proyectos de innovación abierta, para aportar valor a la sociedad, en esta nueva normalidad. Por tal motivo, Invitamos a Endesa y Prosegur, dos de las empresas patrono de la Cátedra de Industria Conectada, a compartir sus experiencias con nosotros. Los ponentes invitados fueron **Juan Antonio Garrigosa de Sigmaringa**, Head of Business to Government (B2G) de ENDESA X y **José Daniel García Espinel** Innovation Director PGA, PROSEGUR.

Mariano Ventosa y Bernardo Villazán, codirectores de la Cátedra, participaron como moderadores de la sesión.

3. LA PERSONA EN EL CENTRO - Digitalización Post Covid-19



3, 10, 17 Y 24 DE NOVIEMBRE

FORMATO
HÍBRIDO



La Cátedra de Industria Conectada organizó un ciclo de encuentros en el que participaron los CEOs de las empresas patrono.

Para abordar la incidencia de la digitalización en la era post Covid-19, la Cátedra de Industria Conectada de Comillas ICAI celebró el ciclo *“La persona en el centro”*, los martes 3, 10, 17 y 24 de noviembre. A lo largo de cuatro sesiones, los CEOs de las empresas patrono de la Cátedra abordaron temas como la movilidad, la ciberseguridad, el teletrabajo, la sostenibilidad o la realidad aumentada.

Raül Blanco, secretario general de Industria y PYME, del Ministerio de Comercio, Industria y Turismo participó en la mesa de apertura del 3 de noviembre señalando la importancia de llevar a cabo una inversión industrial centrada en las PYMES. También participaron Bernardo Velázquez, consejero delegado de Acerinox, y Jesús Pascual, consejero delegado de Grupo Antolin.



Primera sesión del ciclo "La persona en el centro"

Velázquez apuntó: "Las empresas tenemos que ser tremendamente flexibles, ser capaces de predecir todas las situaciones y reaccionar muy rápidamente, ágiles para tomar decisiones y adaptarnos a las nuevas situaciones, y unas cadenas de suministro cortas que sean capaces de reaccionar a estas necesidades".

"En Grupo Antolin estamos aplicando todo el potencial de la digitalización de forma transversal a cualquier actividad y departamento siempre que aporte valor añadido y a un coste razonable", explicó Pascual.



Raúl Blanco, secretario general de Industria y PYME, Ministerio de Industria, Comercio y Turismo



Bernardo Velázquez, consejero delegado de Acerinox



Jesús Pascual, consejero delegado de Grupo Antolin



Segunda sesión del ciclo "La persona en el centro"

La mesa del 10 de noviembre estuvo compuesta por Marc Gómez, consejero delegado y presidente de ABB España, Eduardo López-Puertas, director general de IFEMA, y Juan de Navascués, director general de Saargummi Ibérica. Gómez señaló: "No hay alternativa, todos tenemos que actualizarnos, sin esperar a que lleguen las nuevas generaciones". López-Puertas, por su parte, reconoció que "talento, estrategia y flexibilidad son las claves de la digitalización". Para Navascués, "es la persona la que aporta valor a la tecnología".



Marc Gómez, consejero delegado y presidente de ABB España



Eduardo López-Puertas, director general de IFEMA



Juan de Navascués, director general de Saargummi Ibérica



Marcelino Oreja, consejero delegado de Enagás



Fernando Abril-Martorell, presidente de Indra



Enrique Ramírez, director general de Pladur

Marcelino Oreja, consejero delegado de Enagás, Fernando Abril-Martorell, presidente de Indra, y Enrique Ramírez, director general de Pladur, participaron en la jornada del 17 de noviembre. Oreja insistió en la necesidad de “formar a las personas en aquellas cuestiones que son necesarias para el futuro”. En la misma línea, Abril-Martorell incidió en el valor de la tecnología y la digitalización para aumentar la productividad y competitividad de compañías e industrias. Ramírez recalcó que “el mayor reto de la transformación digital es la resistencia al cambio”.



Tercera sesión del ciclo “La persona en el centro”



Cuarta sesión del ciclo "La persona en el centro"

La encargada de cerrar el ciclo el 24 de noviembre fue la secretaria de Estado de Digitalización e Inteligencia Artificial, Carme Artigas, quien estuvo acompañada por el presidente de IBM España, Portugal, Grecia e Israel, Horacio Morell, y por el presidente ejecutivo de Gestamp, Francisco J. Riberas. Durante su intervención, la secretaria de Estado recordó que: "La transformación digital es uno de los mayores retos de nuestro país, y también una oportunidad histórica. La pandemia nos ha recordado que lo que era importante se ha transmitido en urgente. Gracias a la digitalización hemos podido mantener la actividad económica. Hemos adelantado años de avance".



Horacio Morell, presidente de IBM España, Portugal, Grecia e Israel



Carme Artigas, secretaria de Estado de Digitalización e Inteligencia Artificial



Francisco J. Riberas, presidente ejecutivo de Gestamp



Bernardo Villazán, codirector de la Cátedra de Industria Conectada y moderador de las cuatro sesiones

Morell señaló a la formación como la clave y afirmó que “la tecnología va a acelerar nuestra capacidad para descubrir” y Riberas apuntó: “La industria 4.0. ha de ser verde, sostenible, digital e inclusiva”.

A la clausura también asistieron el rector de la universidad, Julio L. Martínez, SJ, y el vicerrector de Investigación e Internacionalización y codirector de la Cátedra, Mariano Ventosa. El rector insistió en la idea de la crisis de la Covid-19 como oportunidad: “La pandemia ha puesto a prueba a la humanidad, en un desafío que también es una oportunidad para poner el bien común en el horizonte de todos los esfuerzos”.

“El principal reto de la universidad en esta nueva revolución industrial es adaptarse y actualizarse a la misma velocidad a la que cambia el contexto”, remarcó Ventosa. Bernardo Villazán, codirector de la Cátedra y moderador de las cuatro sesiones, cerró el ciclo recalcando que “nada tendría sentido sin la persona en el centro”.



Julio L. Martínez, SJ, rector de la Universidad Pontificia Comillas, durante la clausura del ciclo “La persona en el centro”

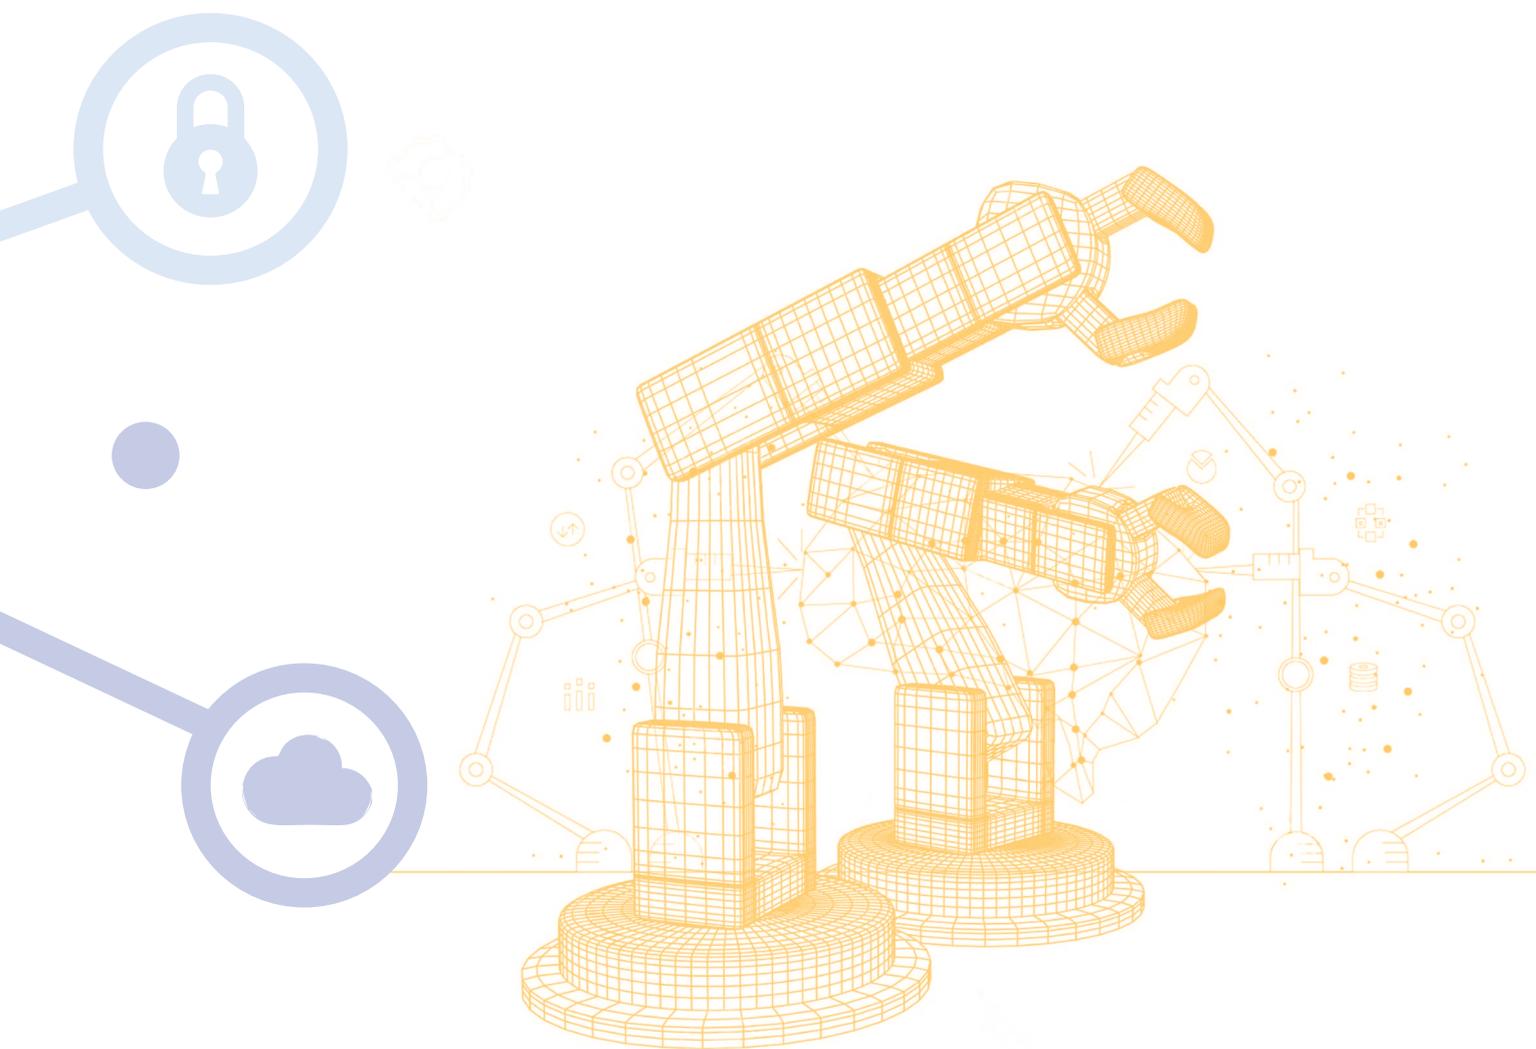
Si te lo perdiste puedes acceder a todas las sesiones en este enlace:

 https://tv.comillas.edu/playlist/1_s4txbdbm



IV HACKATHON FOR SMART INDUSTRY

A través de la organización de su tradicional **Hackathon**, la Cátedra promueve un **espacio de colaboración entre alumnos y empresa** en el que los alumnos aplican los conocimientos adquiridos en el aula para solucionar un caso real y la empresa obtiene una visión innovadora que resuelve el reto que plantea.



IV HACKATHON FOR SMART INDUSTRY



20 Y 21 DE
NOVIEMBRE

COLABORACIÓN
CON:



PROSEGUR

FORMATO
ONLINE



“Ocho equipos ofrecieron respuestas al reto propuesto por la Cátedra de Industria Conectada y Prosegur”

Los días 20 y 21 de noviembre se celebró la **cuarta edición del Hackathon for Smart Industry**, organizado por la Cátedra de Industria Conectada de Comillas ICAI, este año en colaboración con la empresa patrono **Prosegur**.

Esta iniciativa albergó a más de 50 participantes, de los Grados y Másteres de la Escuela y del Programa Avanzado en Industria Conectada, Liderazgo y Transformación Digital, que tuvieron que dar respuesta al reto planteado por Prosegur en poco más de 24 horas.

Los participantes, repartidos en ocho equipos, trabajaron intensamente para dar una respuesta original al reto planteado por el área de innovación de Prosegur: **cómo mejorar la eficiencia de la gestión del efectivo de sus dispositivos “Prosegur Smart Cash”**.

Cada equipo puso en práctica sus habilidades y contó con el apoyo de diferentes profesionales de la compañía para resolver todas sus dudas. Finalizado el tiempo establecido de trabajo, expusieron sus soluciones ante el jurado, que evaluó todas las propuestas seleccionando las mejores.

El jurado formado por Carolina García Cortes, José Daniel García Espinel, Felipe Gómez, Juan Estalella Girón, expertos de Prosegur, y Enrique Fernández Puertas, como experto independiente por parte de Repsol, dio a conocer a los ganadores al finalizar la jornada del sábado:



Primer puesto para el equipo 6 formado por: Álvaro Luis Fernández Blázquez, Javier Colinas, Manuel Trabado, Nicolás Santiago, Ángel Sánchez Sierra, Fernando Mateos García y Susana Mencía Pérez.



Segundo puesto para el equipo 4 integrado por: Gabriela Martín Carballo, Ana Abad Arboiro, Alicia Sanz de la Escalera, Alfonso Sanz Giner, Blanca Lluch Ponce, Javier Villa Escudero y Agustín Sánchez Ríos.



Tercer puesto para el equipo 5 formado por: María del Carmen Rubiales Mena, Roberto Gesteira Miñarro, Laura Martínez de Guinea García, Nora Segura Vallejo, Ignacio Ortiz de Zúñiga, Eduardo Zubillaga Solano y Federico Javier Navarro Leach.



La ceremonia de entrega de premios se realizó el 26 de noviembre en la Sala de conferencias de ICAE. A la misma, acudieron los premiados junto a **José Daniel García Espinel** como representante del jurado, **Bernardo Villazán Gil**, codirector de la Cátedra de Industria Conectada de Comillas ICAI y **Pablo García González**, director de Estudios de Postgrado y Doctorado de Comillas ICAI. Durante la ceremonia, José Daniel comunicó a los premiados las intenciones de Prosegur de continuar trabajando con los alumnos para poder implementar algunas de las soluciones propuestas.

Agradecemos a todos los alumnos participantes y a los miembros del jurado por su tiempo, entusiasmo y dedicación.



Bernardo Villazán Gil, codirector de la Cátedra de Industria Conectada de Comillas ICAI



José Daniel García Espinel, director de Innovación de Prosegur y representante del jurado



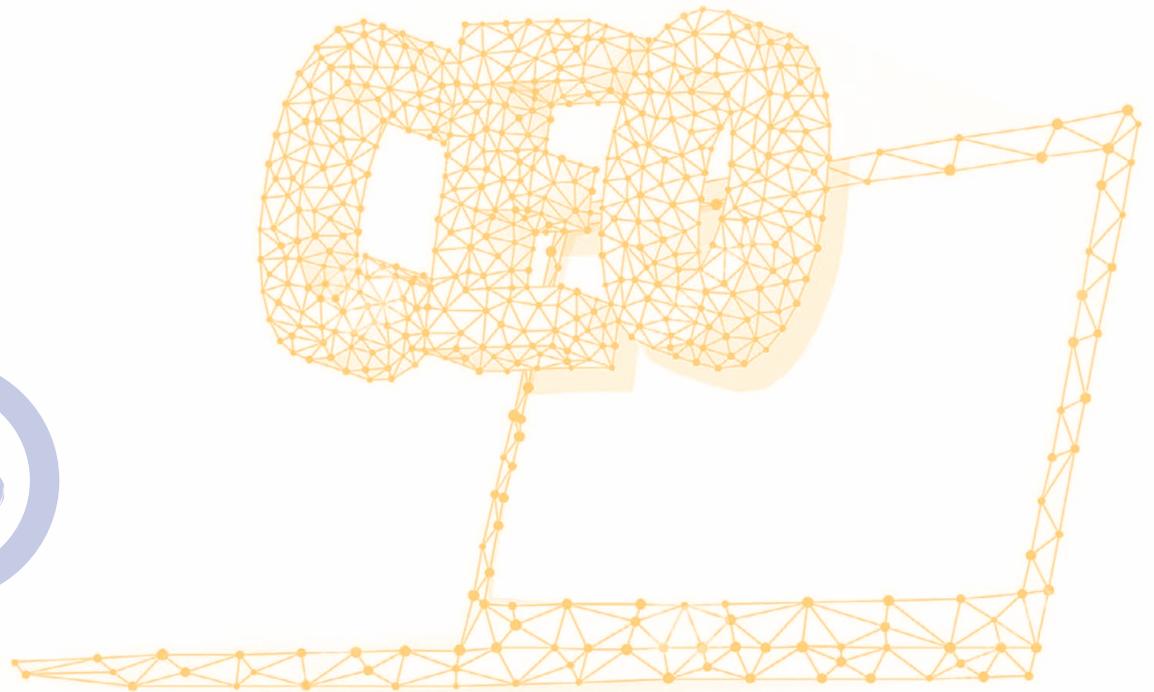
Pablo García González, director de Estudios de Postgrado y Doctorado de Comillas ICAI



DESAYUNOS CON CEO

Desayunos con CEO es una iniciativa que la Cátedra de Industria Conectada organiza desde su fundación con el objetivo de **analizar las tendencias de un sector**. En ellos, el Presidente/CEO de una empresa expone, ante destacados representantes de empresas industriales y otros directivos relevantes de las empresas patrono, la situación de su sector, las tendencias actuales, así como el peso de la tecnología en el proceso de digitalización de sus compañías. En 2020, debido a la situación sanitaria generada por el Covid-19, hemos adaptado estos tradicionales encuentros al formato online o híbrido presencial-online.

Este año se han organizado cuatro Desayunos con CEO y los protagonistas invitados han sido, categorizados por orden cronológico: **Jesús Sánchez-Quñones**, CEO de Renta4; **Juan de Navascués**, Managing Director de SaarGummi Ibérica; **Ezequiel Szafir**, CEO de Openbank y **María Helena Antolin**, vicepresidenta de Grupo Antolin.





1. JESÚS SÁNCHEZ-QUIÑONES, CEO de Renta4



7 DE MAYO

FORMATO
ONLINE



Jesús Sánchez-Quiñones, CEO de Renta4

El primer Desayuno CEO del 2020, se realizó el 7 de mayo de forma virtual.

En esta oportunidad contamos con **Jesús Sánchez-Quiñones**, consejero y director general de Renta4 Banco, como ponente invitado.

Durante la sesión, Sánchez-Quiñones compartió su **visión económica y de mercados en la situación Covid-19**.

El rector de la universidad, **Julio L. Martínez, SJ**, participó dando la bienvenida al ponente y a la audiencia; y **Bernardo Villazán**, codirector de la Cátedra, participó como moderador.

2. JUAN DE NAVASCUÉS, CEO de SaarGummi Ibérica



2 DE JULIO

FORMATO
ONLINE

Juan de Navascués Benlloch, CEO de SaarGummi Ibérica

El segundo Desayuno CEO del 2020, se realizó el pasado 2 de julio de forma virtual.

En esta oportunidad el ponente invitado fue **Juan de Navascués Benlloch**, President Operations Steering Committee Worldwide & Managing Director de SaarGummi Ibérica, empresa patrono de la Cátedra.

Durante la sesión, tuvimos la oportunidad de dialogar con el ponente sobre **la importancia del compromiso de todos con la industria e intercambiar experiencias ante la crisis generada por el Covid-19.**

El rector de la universidad, **Julio L. Martínez, SJ**, participó dando unas palabras de bienvenida; y **Bernardo Villazán**, codirector de la Cátedra, participó como moderador.

3. EZEQUIEL SZAFIR, CEO de Openbank



13 DE JULIO

JUNTO A:

CLUB
EMPRESARIAL
ICADE

FORMATO
HÍBRIDO



Ezequiel Szafir, CEO de Openbank
durante su intervención

El tercer encuentro con CEOs del 2020 fue coorganizado por la Cátedra de Industria Conectada y el Club Empresarial ICADE y se llevó a cabo el lunes 13 de julio.

En esta ocasión adaptamos los tradicionales desayunos de verano, a un encuentro híbrido, donde los ponentes participaron de forma presencial en la universidad y la audiencia se conectó en remoto, garantizando así las medidas de seguridad por el Covid-19.

El invitado en esta oportunidad fue **Ezequiel Szafir**, CEO de Openbank, quien compartió su visión sobre la **“Revolución digital: entre el pánico innecesario y la peligrosa negación”**.

Ezequiel puso de manifiesto, apoyado en casos prácticos reales, los errores en la toma de decisiones de la alta dirección de las empresas, de todo tamaño y sector de actividad, al afrontar los enormes retos que se derivan de la turbulencia del entorno, principalmente de la disrupción tecnológica.

El rector de la universidad, **Julio L. Martínez, SJ**, participó dando la bienvenida al ponente y a la audiencia; y **Jaime Pérez Renovales**, presidente del Club Empresarial ICADE, participó como moderador de la sesión.



4. MARÍA HELENA ANTOLIN, Vicepresidenta de Grupo Antolin



10 DE SEPTIEMBRE

JUNTO A:



FORMATO
HÍBRIDO



María Helena Antolin, Vicepresidenta de Grupo Antolin durante su intervención

El último encuentro con CEOs del 2020, fue realizado el 10 de septiembre en colaboración con el Club Empresarial ICADE. En esta ocasión, la invitada

fue María Helena Antolin, vicepresidenta de Grupo Antolin, empresa patrono de la Cátedra.

María Helena Antolin comenzó su intervención haciendo una breve presentación de la compañía, empresa familiar multinacional de referencia en el sector del automóvil, y de la situación actual tras la crisis de la Covid-19. Recalcó que “siempre se mantuvo una línea de comunicación con los empleados, lo cual ha sido muy importante en los momentos de incertidumbre”.

La vicepresidenta de Grupo Antolin centró su conferencia en **los retos y el futuro de la industria de la automoción**. “Cambian los hábitos y la tecnología, y debemos cuidar del medio ambiente y comprometernos con los ODS y con el futuro”, apuntó. Por ello, hay que “acercar la universidad a la empresa. Es clave. Hace falta atraer el talento a la industria porque la industria es lo que da riqueza, es lo que ayuda a superar las crisis, una industria sólida, sostenible, es lo que da valor y futuro”, concluyó.

Al desayuno, que tuvo formato híbrido presencial-virtual debido a las circunstancias provocadas por la pandemia, se conectaron de manera telemática representantes de las empresas patrono de la Cátedra de Industria Conectada, y miembros del Club Empresarial ICADE.

Presidió el acto el Rector de la universidad, **Julio L. Martínez, SJ**, acompañado del codirector de la Cátedra de Industria Conectada, Bernardo Villazán, que presentó a la ponente y moderó el coloquio, y del Presidente del Club Empresarial, Jaime Pérez Renovales.





INVESTIGACIÓN



Después de completar su rodaje el año anterior, 2020 ha servido para consolidar al CIC LAB como el vehículo para canalizar la investigación aplicada a problemas reales de la industria en el seno de la Cátedra de Industria Conectada. Y nada mejor para ello que responder a una serie de retos propuestos por las distintas empresas patrono.

Concretando, a principios de junio arrancó la segunda edición de verano del CIC LAB en la que se trabajó en siete retos que consistían en problemas reales de la industria. Para resolverlos, contamos con 35 alumnos de la ETSI-CAI, principalmente del Máster en Ingeniería Industrial (MII) combinado con el Máster en Industria Conectada (MIC), pero también de los Grados en Ingeniería en Tecnologías Industriales (GITI) y en Ingeniería en Tecnologías de Telecomunicación (GITT). Esta cifra refleja el atractivo para nuestros estudiantes de este tipo de iniciativas en las que la industria se acerca a la universidad, algo que les permite aportar valor incluso antes de terminar su formación.

Si se analiza la transformación en las líneas de trabajo y en los intereses del CIC LAB como resultado de la interacción con los patronos, podrá verse que el cambio es importante. Ahora, la investigación está mucho más aterrizada en problemas concretos. Sin embargo, la agilidad con la que los estudiantes han respondido a una serie de retos tan ambiciosos y diversos como los que presentaremos a continuación, no habría sido posible sin apoyarse en el trabajo previo de los estudiantes del CIC LAB. En este sentido, conviene destacar que las líneas de trabajo impulsadas desde septiembre de 2019 hasta mayo de 2020 sirvieron para desarrollar e interiorizar las herramientas básicas que luego se pusieron al servicio de la solución de los retos mencionados.

Tras la edición de verano, algunos retos han tenido continuidad, y de hecho cuatro estudiantes del MIC están realizando sus Trabajos de Fin de Máster dentro del CIC LAB. Además, hemos comenzado a trabajar en un nuevo reto.

A continuación, os detallamos los siete proyectos en los que trabajamos en verano de 2020 y las líneas de trabajo que han quedado activas.



1. LA EDICIÓN DEL CIC LAB DE VERANO DE 2020

La edición del CIC LAB del verano de 2020 tuvo, como cabe esperar, una serie de particularidades provocadas por la pandemia del Covid-19. La más notable es que se trató de una edición virtual, en la que los estudiantes trabajaron siempre en remoto, aprovechando las herramientas colaborativas que ya se habían convertido en un estándar después del final de semestre no presencial (principalmente MS Teams).

Sin embargo, la singularidad más importante es que en esta ocasión contamos, como hemos presentado en la introducción del capítulo, con siete retos reales propuestos por algunas de las empresas patrono de la Cátedra. A saber:

- OPTIMIZACIÓN DE ALMACÉN - SAARGUMMI
- VISIÓN ARTIFICIAL - PROSEGUR
- DESTREZA ROBÓTICA - GRUPO ANTOLIN
- TRADING EN MERCADOS DE *COMMODITIES* - REPSOL
- IIOT EN ENTORNOS ATEX - REPSOL
- ANALÍTICA AVANZADA EN LA RED DE DISTRIBUCIÓN - ENDESA
- CIBERSEGURIDAD INDUSTRIAL - ENDESA

Profesores e investigadores de la ETSI-ICAI y expertos externos que colaboraron en el CIC LAB del verano 2020:

- Lucía Güitta. Investigadora junior de la Cátedra de Industria Conectada
- José Portela. Profesor de Comillas-ICADE e investigador del IIT
- Pedro Sánchez. Profesor de Comillas-ICAI
- Gregorio López. Profesor de Comillas-ICAI
- Javier Jarauta. Profesor de Comillas-ICAI y Director de Consultoría de SIA
- Antonio Pérez. Grupo SIA
- Luis Salado. Grupo SIA
- Juan Cornago. Grupo SIA
- Álvaro López. Coordinador del CIC LAB

Y a pesar de estas novedades, el espíritu del CIC LAB de verano fue el mismo: trabajo en equipos de entre 4 y 6 personas en los que se mezclaron estudiantes de distintos cursos. Sesiones diarias de coordinación/seguimiento de 10 minutos para velar porque los equipos tuvieran lo necesario para poder avanzar (detalles concretos del problema propuesto, apoyo de profesores de ICAI o investigadores del IIT, etc.) y sesiones de trabajo colaborativo el resto de la jornada. Luego, con frecuencia semanal, se presentaron los avances a los patronos, algo que sirvió para orientar de forma optimizada los trabajos.

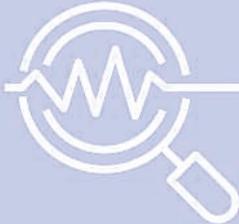
Hemos constatado que las dinámicas de trabajo del CIC LAB de verano, en las que colaboran varios alumnos de distintos niveles permiten responder de manera eficaz a retos de una complejidad claramente superior a la que manejan los estudiantes en

sus estudios. Los estudiantes de nivel Máster orientan el trabajo de los de nivel Grado, que no obstante ya son capaces de aportar ideas y frescura a las discusiones de los equipos.

A continuación, pasamos a describir los detalles y los resultados obtenidos en los retos antes mencionados.

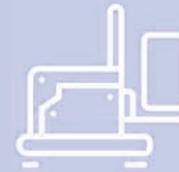
- OPTIMIZACIÓN DE ALMACÉN - SAARGUMMI

IMPLEMENTACIÓN Y OPTIMIZACIÓN DE AGVs EN LA PLANTA DE PRODUCCIÓN



Alumnos:

Álvaro Martínez Cuenca,
Carlos Moro García,
Íñigo Manrique Bautista,
José Gil Fernández,
Nerea Zabala Orive



I. INTRODUCCIÓN

En este proyecto, se estudia la inclusión de AGV's para el traslado de producto terminado y empaquetado desde las distintas líneas de producción hasta la zona de *picking* en la planta de SaarGummi en Loeches, Madrid. En la planta de SaarGummi se producen perfiles de estanqueidad para diferentes tipos de automóviles del panorama internacional, actualmente las cajas de producto terminado son movidas por carretilleros directamente hasta el almacén de productos terminados. Con la inclusión de AGVs se quiere evitar que los operarios de la fábrica se tengan que dedicar a mover carretillas, permitiendo que se dediquen a tareas de más valor añadido, y optimizando en definitiva los costes de operación.

Durante este proyecto se ha creado un modelo con el software *Arena Simulation* para simular distintos escenarios y proporcionar información sobre cuántos AGVs se necesitan, qué recargas de baterías serían las óptimas y la viabilidad del proyecto. Además se realiza la comparativa entre dos tipos distintos de AGVs, el MIR 500 y el Seit 500.

2. MODELO DE LA PLANTA

El modelo generado permite simular distintos escenarios de recogida de producto terminado en la planta, cambiando variables como la velocidad de los AGVs o la producción de la planta, entre otros. El modelo incluye todas las líneas cuyo producto se traslada con el proceso logístico que se desea automatizar en este estudio (un total de 4).

Para generar el modelo de forma realista, se utiliza la información recibida por parte de SaarGummi en cuanto a funcionamiento de la planta, y las características encontradas sobre cada tipo de AGV. Este modelo se crea con el software *Arena Simulation* y se enfoca en simular, tanto toda la logística necesaria para el proyecto, como una simulación visual en 2D del movimiento de los AGVs por la planta.

Parámetros

Los parámetros del modelo definen su comportamiento, y se han inferido tanto con la información recibida por SaarGummi, como de la posterior visita a la fábrica.



- **Generación de producto terminado en las líneas:** Para los parámetros de generación de producto, la empresa proporciona las medias de tiempo que tarda cada línea en sacar producto terminado. Aquí, se diferencian dos tipos de distribuciones: las líneas que empaquetan una caja por vez, y las líneas que empaquetan dos cada vez. Para parametrizar estos *outputs*, se decide que, en el primer tipo de línea se genere un producto terminado cada media de tiempo, sin ningún componente aleatorio; mientras que en el segundo tipo de líneas, se modelan los *outputs* como dos distribuciones normales, donde cada una refleja el empaquetado de una de las cajas. Esto se hace así para poder evaluar la posibilidad de que dos cajas se terminen de empaquetar en el mismo instante, creando más colas de producto terminado. Además, estas dos distribuciones normales están desviadas en el tiempo para que lo más probable no sea que salgan las dos cajas a la vez. Las distribuciones utilizadas con las siguientes:
 - Línea 1: un paquete cada 25 minutos.
 - Línea 2: dos distribuciones normales con media 40 minutos y desviación típica 5, la segunda normal está desviada en el tiempo 5 minutos con respecto a la primera.
 - Línea 3: dos distribuciones normales con media 34 minutos y desviación típica 5, la segunda normal está desviada en el tiempo 3 minutos.
 - Línea 4: un paquete cada 12 minutos.
- **Distancias entre los puntos de carga y descarga:**
 - Línea 1 a zona de descarga: 160 metros
 - Línea 2 a zona de descarga: 146 metros
 - Línea 3 a zona de descarga: 108 metros
 - Línea 4 a zona de descarga: 100 metros
- **Prioridades del AGV:** Al definir el movimiento del AGV, se prioriza que se recojan los paquetes de las líneas con más paquetes en espera a ser recogidos. Así, se minimizan las colas de producto terminado a la salida de las líneas.
- **Delay por carga y descarga del material:** Tras analizar varios vídeos del funcionamiento de los AGVs, se ha estimado que tarda un minuto en recoger y descargar material en las plataformas.
- **Delays por cruces:** En este *delay* se tienen en cuenta todas las maniobras o paradas que tenga que realizar el AGV en el trayecto para la recogida de un producto. Para empezar, se estima un *delay* base para cada línea de producto, que sería el tiempo que pierde el AGV por no ir totalmente recto en su trayectoria. Estos *delays* son de 25, 20, 10 y 15 segundos empezando desde la línea más alejada hasta la más cercana (en trayecto de ir hacia la línea y volver hasta la zona de *picking*). Además, se generan distintos escenarios de cruce de personas, AGVs y carretilleros que podrían causar *delays* estimados con unas probabilidades asociadas que se muestran a continuación:
 - Con probabilidad del 5% el AGV se cruza con 4 personas, 1 carretillero y otro AGV, con esto se pierden 45 segundos.
 - Con probabilidad del 15% el AGV se cruza con 2 personas, 1 carretillero y otro AGV, con esto se pierden 35 segundos.
 - Con probabilidad del 20% el AGV se cruza con 3 personas y otro AGV, con esto se pierden 20 segundos.
 - Con probabilidad del 50%, el AGV se cruza con 1 persona y otro AGV, con esto se pierden 10 segundos.
 - Con probabilidad del 10% no se cruza con nada y por tanto no pierde tiempo.

- **Tipos de carga:** Al evaluar los tipos de carga posibles, se decide optimizar la vida útil de la batería, reduciendo así el coste de mantenimiento de los AGVs. Para ello se alarga lo máximo posible el tiempo hasta que se cargue la batería, sin excederse para no quedarse sin batería alguno de los AGVs en ningún momento.

Para parametrizar esto en el modelo, se mandaba una orden de carga cada cierto tiempo, que hacía que los AGVs fuesen a la zona de *picking* y permaneciesen allí el tiempo suficiente para completar la carga. Es necesario mencionar que, al haber dos AGVs, se van alternando para ir a recargar, y el tiempo que destinan a la producción será el tiempo entre cargas menos el tiempo necesario para la carga de estos (que varía entre el MILVUS y el MIR). Estos tiempos de recarga son algo conservadores, ya que según lo mencionado, se podría seguir aumentando el tiempo de actividad de los AGVs hasta casi agotar la carga, disminuyendo también los tiempos de espera de producto en las líneas.

A continuación, se analizan los parámetros escogidos para cada tipo de AGV. Se ha optado por simular escenarios en los que se maximice la vida de la batería, lo que se logra alargando los períodos entre cargas lo máximo posible.

Tipo de carga y velocidad del MIR 500

Tanto el tipo de carga como la velocidad del AGV son parámetros que varían según el modelo de AGV, para el MIR 500 su autonomía es de 8 horas y tarda 1 hora en cargarse, pero para que el AGV nunca se quede sin batería al realizar un pedido, se parametrizó que se mande una orden de carga cada 3.3 horas (200 minutos). El tiempo de operación de cada AGV entre cada recarga será por tanto de 400-60 (tiempo en recargar) = 340 minutos, que se puede satisfacer con la autonomía del AGV. La velocidad será de 1.5 m/s, valor cercano al máximo requerido según los estándares de seguridad.

Tipo de carga y velocidad del Milvus Seit 500

Según sus características técnicas, se requieren 2 horas para alcanzar una carga del 80% y 3 horas para cargarlo completamente. Tanto el tipo de carga como la velocidad son parámetros que varían según el modelo de AGV, para el Seit 500 en este caso, se mandará la orden de la recarga cada 200 minutos, en la que sólo se recargará un AGV cada vez. El tiempo de recarga será de 2 horas. El tiempo de operación de cada AGV entre cada recarga será por tanto de 400-120 (tiempo en recargar) = 280 minutos (que es menor que el 80% de la autonomía de 8 horas, por lo que podrá lograrlo sin problema). Con respecto a su velocidad, se ha simulado con una velocidad máxima de 1.4 m/s, a pesar de que según sus especificaciones sea de 1.5 m/s, de esta manera aplicamos un pequeño margen de seguridad por si la velocidad se reduce en caso de que lleve una carga encima.

Como se observará en el siguiente apartado, los tiempos de carga elegidos para el escenario en el que se maximiza la batería no son capaces de mantener el máximo número de paquetes a la salida de las líneas en un valor inferior a 3 (en las líneas 2 y 3, que son las que tienen un *output* de cajas de dos en dos). Para solucionar este aspecto, y puesto que la velocidad de operación no se puede aumentar, se optará por reducir el tiempo entre recargas, disminuyendo también el tiempo requerido para cargar. El tiempo entre las órdenes de recarga será de 175 minutos (frente a los 200 minutos originales). De nuevo, sólo se recarga un AGV cada vez, por lo que cada AGV irá a cargar cada 350 minutos). El tiempo de recarga será ahora 85 minutos, por lo que el tiempo de operación total entre cargas será $350 - 85 = 265$, que es más que la autonomía que se consigue con la carga de esos 85 minutos (271 minutos de operación, aproximadamente un 57%).



3. RESULTADOS

En esta sección se presentan las simulaciones y resultados, para poder evaluar con ello la viabilidad y el funcionamiento del proyecto.

3.1. Simulaciones

Las simulaciones realizadas con el modelo representan el funcionamiento de la planta con parámetros muy conservadores, es decir, se simulan los peores escenarios posibles para poder asegurar la viabilidad del proyecto. Los parámetros base son los descritos en la sección anterior: la distribución de salida de cada línea (**L1, L2, L3 y L4**), la velocidad del AGV (**Vel AGV**), el tiempo hasta la carga (**Time 2 Charge**) y el tiempo de carga (**Time Charging**).

Para las simulaciones se modifica (en las dos primeras) la distribución que regula la salida de producto terminado en la línea 2, para evaluar los dos posibles escenarios de producción (**Container tipo 1 o 2**), siendo más exigente para los AGVs la producción del *Container* tipo 2. Es necesario mencionar que, aunque en las líneas 2 y 3 pueden producirse dos productos diferentes, dependiendo del día y las necesidades, se analizará el producto con un menor tiempo de salida, y que por tanto comprometerá más a los AGVs. Se simulan, para el caso de la línea 2, los escenarios correspondientes a la salida de cada producto. En la línea 3, ambos productos tienen los mismos tiempos de salida, por lo que se simulará solo ese escenario.

Al sobrarle prestaciones al MIR, en la última simulación se reduce el factor de tiempo al 85% para saber cuánto se puede subir la producción de la planta en este escenario. El tiempo de simulación es de una semana. Además, como el MILVUS acumula bastantes veces tres paquetes en cola con el caso base, se realiza una simulación cambiando la gestión de la batería para minimizar este evento. Se le manda a cargar cada 175 minutos y está 85 minutos cargando.

3.1.1. MIR 500

En el caso del MIR 500, la velocidad máxima es de 2 m/s, pero por seguridad estimamos una velocidad de 1.5 m/s. Para las simulaciones se estipula un tiempo de carga de 60 minutos.

Tabla : ESCENARIOS MIR 500

	ENTRADAS								
	AGV	Factor (al tiempo)	L1	L2	L3	L4	Vel AGV	Time 2 Charge	Time Charging
Container 1	MIR 500	1	25	$N(50, 5)$	34 (5)	12	1,5	200	60
Container 2	MIR 500	1	25	$N(40, 5)$	34 (5)	12	1,5	200	60
Aum. Producción	MIR 500	0,85	21,25	$N(34, 5)$	28,9 (5)	10,2	1,5	200	60

3.1.2. Milvus Seit 500

Para el Seit 500 estimamos una velocidad de 1.4 m/s (considerando un pequeño margen de seguridad), ya que su máximo es de 1.5 m/s, a diferencia del MIR que eran 2 m/s. El Seit 500 tarda el doble de tiempo en cargarse. Cabe destacar que para el Seit no se realiza la simulación de aumento de producción, porque para el escenario extremo analizado está trabajando en su límite, si bien se simula el cambio de la gestión de baterías para mejorar los paquetes en cola.

Tabla : ESCENARIOS SEIT 500

	ENTRADAS								
	AGV	Factor (al tiempo)	L1	L2	L3	L4	Vel AGV	Time 2 Charge	Time Charging
Container 2	SEIT 500	1	25	N (40, 5)	N (34, 5)	12	1,4	200	120
Container 1	SEIT 500	1	25	N (50, 5)	N (34, 5)	12	1,4	200	120
Container 2	SEIT 500	1	25	N (40, 5)	N (34, 5)	12	1,4	175	85
Container 1	SEIT 500	1	25	N (50, 5)	N (34, 5)	12	1,4	175	85

3.2. Resultados

Las simulaciones permiten obtener datos sobre la producción y el funcionamiento de los AGVs. La comparativa se centra en el tiempo promedio de espera de los productos terminados en cada línea en minutos (**Media tx**) y el máximo número de productos terminados acumulados por línea (**Max Lx**). Debido a la preocupación de que la cola de las líneas exceda 3 productos terminados, por la falta de espacio para las plataformas de recogida, se ha simulado cuántas veces se daría esta situación en la producción de una semana (**n Veces**). La razón de contabilizar este hecho es porque los parámetros elegidos para la simulación son un poco más exigentes que los reales, por lo que no sería tan común una vez aplicado que se diese esta situación. También se obtiene el uso de los AGVs con el porcentaje de tiempo que están en funcionamiento o cargando (**Uso**). Finalmente, se realiza un análisis de cuántos se puede llegar a explotar el AGV sin que sature si se aumentase la producción.

3.2.1. MIR 500

Resultados de las simulaciones

Tabla : RESULTADOS MIR 500

	ENTRADAS										
	Media t1	Media t2	Media t3	Media t4	Max L1	Max L2	Max L3	Max L4	Uso	Nºde veces	△ Producción
Container 1	4,2	3	1,8	1,2	2	2	2	1	70%	0	1
Container 2	4,8	3	2,4	1,2	2	2	2	1	72%	0	1
Aum. Producción	8,4	6	3,6	2,4	2	3	3	2	82%	4	1,176470588

3.2.2. Milvus Seit 500

Resultados de las simulaciones

Tabla : RESULTADOS SEIT 500

	ENTRADAS										
	Media t1	Media t2	Media t3	Media t4	Max L1	Max L2	Max L3	Max L4	Uso	Nºde veces	△ Producción
Container 2	16,8	11,4	7,8	4,2	2	3	3	2	89%	9	1
Container 1	13,8	9	5,4	3	2	2	3	2	86%	1	1
Container 2	11,4	6,6	4,2	2,4	2	2	3	2	84%	1	1
Container 1	9	5,4	3,6	1,8	2	2	2	2	81%	0	1



Como ya se ha introducido, tras observarse que en el MILVUS, para el escenario en el que se maximiza la batería, se alcanzaban varias veces las 3 cajas a la salida, se optó por sacrificar el uso óptimo de la batería, disminuyendo el tiempo de recarga y el tiempo en ir a cargar hasta que se solventase el problema. Se observa como, reduciendo estos tiempos, se consigue que no se acumulen los paquetes, disminuyendo también el tiempo de espera en las líneas.

Las distintas simulaciones se han llevado a cabo asumiendo la misma producción de un tipo de paquete en la línea a lo largo de toda la semana. Sabiendo que la producción de los tipos de paquetes puede cambiar diariamente, se puede afirmar que los tiempos de salida esperados estarán en un valor intermedio entre ambos. Se observa como cuando se producen cajas del tipo 2 en la línea 2, se obtienen tiempos de espera mayores, al producirse cada menos tiempo.

Se debe mencionar además que el MIR consigue unos resultados mucho mejores, al tener un mayor tiempo de operación, conseguido mediante la carga rápida. Tanto la velocidad como el tiempo en recargar son aspectos fundamentales en la reducción de tiempos de espera en las líneas, como se puede observar al comparar ambas tablas. Aunque no aparezcan en las tablas, se han mantenido los mismos *delays* en todos los escenarios (los mencionados en el apartado 2.2).

Puesto que en el escenario base de producción, el MIR aún podría soportar un escenario más exigente, se demuestra que la producción de todas las líneas podría aumentar hasta un 17% más sin que se almacenasen 3 productos en las líneas.

3.2.3. Comparativa

Con el fin de comparar las cualidades y atributos de ambos modelos, se ha realizado una matriz QFD. En ella, se ponderan los atributos más importantes, se analiza su dependencia con requisitos técnicos funcionales comunes en ambos AGVs y finalmente se obtiene la mejor opción para el proyecto dadas las características de ambos modelos.

Esta primera tabla muestra la importancia de los atributos que se consideran necesarios en los AGVs y los escala por orden de importancia.

Tabla : IMPORTANCIA DE LOS ATRIBUTOS

ATRIBUTO	1.2	1.3	1.4	1.5	Factor	Capacidad	Rango
1. Precio	40%	45%	30%	70%	1,00	0,154	2
2. Tiempo de uso	60%	-	-	-	1,50	0,231	3
3. Velocidad	-	55%	-	-	1,22	0,188	2
4. Fiabilidad	-	-	70%	-	2,33	0,360	4
5. Facilidad de uso	-	-	-	30%	0,43	0,066	1
TOTAL	100%	100%	100%	100%	6,48	1	-

Una vez obtenido este rango, se compara con diferentes aspectos técnicos, se ponderan según el modelo analizado y se obtiene la mejor alternativa.

Tabla : COMPARATIVA DE MODELOS

		Software	Duración de batería	Velocidad de carga	Rapidez de respuesta	Servicio técnico	Calidad/precio	Garantía	
Precio	2	*	*	X	*	X	O	*	
Tiempo de uso	3		O	O			*		
Velocidad	2		*		O		*		
Fiabilidad	4	X				O	*	O	
Facilidad de uso	1	O							
									TOTAL
Importancia cómo		23	31	33	20	42	27	38	214
		0,107	0,145	0,154	0,093	0,196	0,126	0,178	
									Función mérito
MILVUS SEIT		0,5	1	0,7	0,5	0,6	1	0,7	0,721495327
MIR 500		0,7	1	1	0,5	0,8	0,4	0,7	0,752803738

Se puede observar que, para los aspectos analizados, el MIR 500 es el más adecuado, aunque el MILVUS obtiene un resultado muy similar. Las principales diferencias entre ambos modelos son: el precio (en el que el MILVUS consigue un resultado mucho mejor que el MIR, aunque comprometiendo otros aspectos), la velocidad de carga (el MIR consigue una carga mucho más rápida, que permite un mayor aprovechamiento del AGV y una mayor productividad) y el tiempo de respuesta (el MIR al poder ir a una mayor velocidad puede satisfacer la demanda más rápido).

Es importante mencionar que, pese a que el MIR podría soportar un mayor aumento en la producción debido a sus mejores prestaciones técnicas, ambos modelos cumplen con el volumen de producción actual.

4. CONCLUSIONES

Observando los resultados obtenidos en la simulación, y de acuerdo con lo esperado, el volumen de producción actual se puede cubrir con los dos modelos de AGVs. La simulación se ha efectuado teniendo en cuenta los escenarios más desfavorables para todo el horizonte de estudio, por lo que los parámetros reales serán menos críticos que los que se pueden observar en la simulación. Los tiempos entre recarga también son algo conservadores, por lo que, en la realidad, se podría aumentar el tiempo entre recargas, disminuyendo por tanto los tiempos de espera en las líneas.

Para no acumular más de tres paquetes en las líneas, se modifica la gestión de la batería del MILVUS, mandando al AGV a recargar más frecuentemente y menos tiempo. La velocidad del AGV y el tiempo en la recarga de la batería son las variables que ofrecen una mayor sensibilidad en los resultados obtenidos, razón por la que el MIR consigue mejores resultados.



Los AGVs de la marca MIR consiguen un mayor aprovechamiento al tener unos tiempos de carga de batería menores y una mayor velocidad de operación. Respecto al caso base estudiado, la producción puede aumentarse en un 17% en todas las líneas sin llegar a valores críticos. Pese a que se observa que en algunas ocasiones se acumulan 3 paquetes en las líneas que producen dos paquetes a la vez, es poco probable que esto ocurra, ya que es un escenario que se dará eventualmente, y no siempre como en el escenario simulado. Además, se puede comprobar que este evento únicamente ocurriría si se produjese el paquete con más frecuencia de salida durante toda la semana, pero en un escenario normal los paquetes se alternan a lo largo de la semana. Sin embargo, será necesario disponer de dos plataformas de carga de mercancía en cada línea de producto terminado, de acuerdo con los resultados observados.

Pese a obtener peores resultados, y tener peores características generales, la opción de MILVUS resulta atractiva debido a su reducido precio. Al cambiar los ciclos de carga, reduciendo los tiempos entre cada recarga, se consiguen unos resultados satisfactorios, aunque se debe tener en cuenta que el uso de la batería no se está optimizando, y por tanto su vida útil se verá reducida. Considerando que además operará un carretillero de manera paralela a ambos AGVs, y que los *delays* estimados son muy conservadores, ambos modelos de AGV podrán hacer frente a un escenario en el que se aumente el ritmo de producción respecto al caso base analizado, siendo sin embargo el modelo MIR mucho más flexible. Se deben considerar además otros aspectos, como el servicio postventa, el precio de las reparaciones o la garantía.

5. SUGERENCIAS

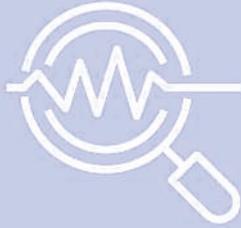
Para garantizar la efectividad y seguridad en la implementación de los AGVs, se deben considerar diferentes aspectos. Pese a requerir un mayor esfuerzo para los operarios de cada una de las líneas, resulta más adecuado situar los puntos de carga cerca del pasillo que directamente en la salida de producto de las líneas, para evitar maniobrar con el AGV en espacios reducidos y reducir el tiempo de espera. Otra opción podría ser habilitar un camino más accesible al que hay actualmente desde el pasillo a la salida de producto. Para evitar cruces excesivos y retrasos en los tiempos (aunque el AGV pueda manejar sin problemas estos aspectos), sería atractivo crear una normativa que impida a los operarios realizar acciones que estorben en mayor medida a los AGVs, como depositar productos en el pasillo o quedarse quieto bloqueando zonas de paso.

Además, como ya se ha mencionado, el hecho de que salgan dos productos simultáneamente de forma frecuente puede comprometer el sistema de recogida. Por ello, se debe procurar que este hecho suceda lo menos posible.

La zona de carga de baterías se debe situar en la zona de descarga del producto (*picking*) al lado del almacén, aprovechando el espacio disponible.

• VISIÓN ARTIFICIAL - PROSEGUR

Este reto, descrito a nivel general como Visión Artificial, constaba de dos retos específicos sobre reconocimiento de acciones y reconocimiento de audio con CNNs.



Alumnos:

Miguel Huertas Collado
 Alberto Menéndez
 Alberto Castillo Rodríguez
 Luis Navarro Velasco
 Lionel Güitta
 Marina Lettieri



▶ VISIÓN ARTIFICIAL: RECONOCIMIENTO DE ACCIONES ◀

1. METODOLOGÍA

En primer lugar, se llevó a cabo un proceso de obtención y clasificación de los vídeos, que es un paso clave para lograr un modelo preciso y fiable. En este estudio, se utilizaron varias webs para descargar el conjunto de datos (*YouTube, Kaggle, UCF...*).

El primer conjunto de vídeos que se introdujeron en la base de datos del proyecto procede de la base de datos de la universidad UCF (University of Central Florida). Estos vídeos fueron clasificados en diferentes categorías como incendio provocado, robo, hurto, etc. Se seleccionaron los relacionados con el robo en tiendas.

En segundo lugar, se descargó el conjunto de datos de Kaggle. Esta base de datos contiene un conjunto procesado de vídeos procedentes de la base de datos UCF 101. Este hecho fue decisivo para descartar estos vídeos de todo el conjunto de datos, ya que eran de mayor interés los vídeos sin procesar.

Posteriormente, para ampliar el conjunto de datos, se implementó un código Python para descargar nuevos vídeos de YouTube, lo cual supuso la fuente principal del conjunto de datos. Estos fueron descargados del canal de TheftCam y otras fuentes.

Una vez se recolectaron todos estos vídeos, se vio la necesidad de aumentar el tamaño de la base de datos, para lo cual se aplicó una técnica de data augmentation. Los vídeos fueron volteados horizontalmente (modo espejo) y añadidos al conjunto de datos con los originales. Esto duplicaría el número de vídeos disponibles.

Finalmente, los vídeos debían tener número de fotogramas constante para poder entrenar la red neuronal con ellos. Para lograrlo, se necesitaba un código de preprocesamiento para dividir los vídeos en trozos más pequeños con una longitud específica, en este caso de 60 fotogramas.



Además, se creó un código para cambiar el nombre del vídeo para normalizar el conjunto de datos para su posterior procesamiento.

Una vez que los experimentos iniciales comenzaron, se vio la necesidad de realizar ciertos cambios en el formato de los vídeos utilizados. Los vídeos eran archivos .mp4, y debido a la cantidad de vídeos que se debían manejar, se superaban los 16 GB de memoria RAM de la que disponíamos. Para resolver este problema, se incluyó un generador de datos en el modelo y, en consecuencia, el formato de los vídeos fue cambiado de .mp4 a .npy para cargar el conjunto de datos correctamente y realizar todo el preprocesamiento de antemano. Finalmente, debido al aún elevado peso de los archivos .npy, se modificó la extensión de los archivos a .npz para mejorar la rapidez del modelo y reducir el peso de los vídeos.

A lo largo del proyecto, se realizaron diferentes conversiones en el modelo. Cuando aparecieron los primeros resultados, fueron extremadamente precisos desde el punto de vista del equipo, lo cual no era de esperar dada la complejidad del problema. Se llevó a cabo un estudio de los resultados obtenidos, y se llegó a la conclusión de que la inteligencia estaba memorizando el entorno en lugar de las acciones. Para evitar que se pudiera memorizar las tiendas que contenían acciones de robo, se incluyó una máscara en los vídeos, que impiden al modelo aprender el fondo del conjunto de datos y, en consecuencia, clasificar erróneamente los archivos. La máscara mencionada fue un detector de movimiento que identifica el movimiento de las personas y muestra el fondo en negro. Esto se logró inicialmente comparando dos cuadros y haciendo la media ponderada, luego llega un nuevo cuadro y la media ponderada se hace con el resultado anterior. Posteriormente, para solucionar de forma definitiva el problema de que la inteligencia pudiera memorizar en qué tiendas hay robo y en cuáles no, se balanceó la base de datos de forma que hubiera de una misma tienda tanto vídeos de robo como de no robo. De esta forma, la inteligencia no podría basarse en la tienda para decidir si hay robo o no, sino que tendría que fijarse en las acciones.

2. EXPERIMENTOS Y RESULTADOS

Para resolver este desafío de ser capaz de detectar hurtos en tiendas, se diseñaron dos modelos diferentes de Aprendizaje Profundo.

2.1. Red Neuronal Convolutiva Tridimensional (3DCNN)

Inicialmente, la arquitectura se construyó con 4 capas Convolutivas y 2 Max Pooling, proporcionando una clasificación robo o de normal. La entrada fue una secuencia de imágenes RGB, que es la razón de utilizar una red 3D. Además, existía la opción de aplicar el detector de movimiento a los vídeos.

Por un lado, el primer experimento se llevó a cabo sin implementar la máscara detectora de movimiento. El conjunto de datos utilizados para este enfoque estaba compuesto sólo por los vídeos de la UCF, con el preprocesamiento antes mencionado. En este caso, los vídeos que presentaban una situación de hurto en tiendas fueron totalmente clasificados como tales. Como resultado, la precisión del modelo fue alta, más del 90% en 30 épocas. De hecho, las curvas de aprendizaje muestran claramente sobreaprendizaje. Por lo tanto, el modelo utilizó las características del fondo del vídeo en lugar de la acción. Por eso se introdujo el detector de movimiento en el modelo que nos permitía eliminar esta característica.

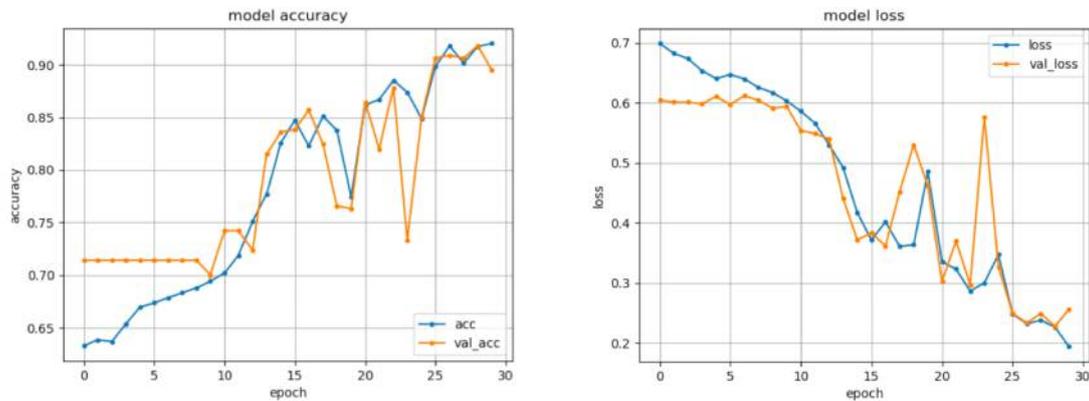


Figura 1. Precisión y resultados de pérdida teniendo los vídeos originales como entrada

Por otro lado, debido a los resultados mostrados anteriormente, en el siguiente experimento se introdujo el detector de movimiento y se modificó el conjunto de datos. Los vídeos de la UCF fueron etiquetados de nuevo. Ahora, los vídeos originalmente clasificados como robos en tiendas fueron divididos en clips donde el ladrón no aparece en la escena (*Normal*) y los que sí lo hacen (*Robo en tiendas*). Por lo tanto, el número de vídeos normales y de hurto en tiendas aumenta además de los nuevos obtenidos de las otras fuentes mencionadas.

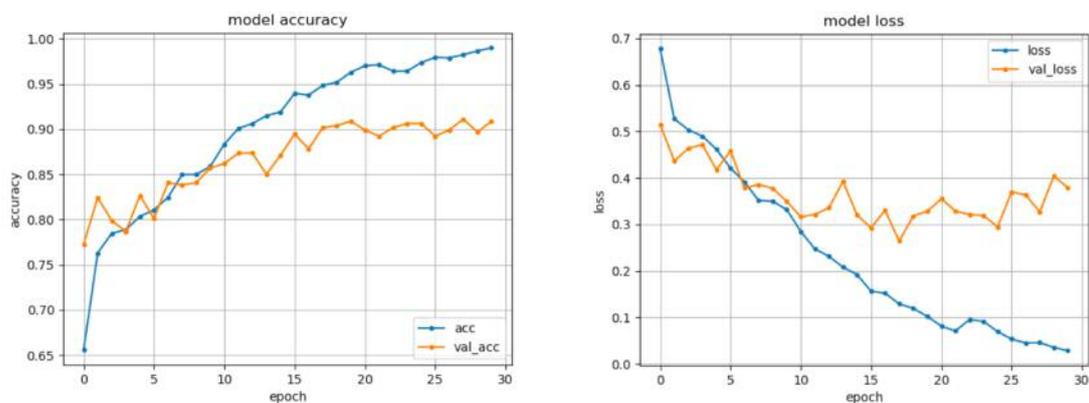


Figura 2. Precisión y resultados de la pérdida teniendo los vídeos del detector de movimiento como entrada

Ahora los resultados son más fiables, ya que el modelo no aprende las características del fondo. Por lo tanto, ahora la prueba no muestra una precisión tan alta como la primera. Sin embargo, las curvas de aprendizaje del set de datos de entrenamiento muestran un sobreentrenamiento e identificamos un problema al dividir el conjunto de datos al azar, ya que se podían encontrar trozos del mismo vídeo en el entrenamiento, la prueba y la validación.

El conjunto de datos se reclasificó para contener sólo la acción de robar en tiendas y los vídeos normales fueron extraídos de las mismas escenas. La intención era eliminar el riesgo de que el algoritmo aprendiera el fondo, así como identificar los rostros de los autores. Cuando se aplicaron estas condiciones, el algoritmo no fue capaz de aprender. Esto podría ser causado por un número reducido de muestras de vídeo en combinación con un problema muy difícil de resolver. Se aplicaron varias



arquitecturas sin éxito. Se debe hacer un mayor ajuste de los hiperparámetros para al menos aprender los datos de entrenamiento.

2.2. Convolutiva bidimensional (Conv2D) + Memoria a largo plazo (LSTM)

El segundo modelo que se implementó para resolver este problema de clasificación de hurto fue un conjunto de capas de Conv2D, al que se le añadió un módulo LSTM. Para utilizar esta arquitectura para clasificar los vídeos, necesitamos preprocesar los vídeos y extraer los fotogramas de cada uno de ellos, ya que a la red convolutiva hay que introducirle fotogramas separados. Esto se debe a la necesidad del Conv2D de recibir imágenes individuales. De cada uno de los vídeos que componían el conjunto de datos, se extrajeron 60 fotogramas, tratando de mantener la frecuencia de fotogramas constante en todos los vídeos.

En este caso, el detector de movimiento no fue probado. El modelo inicial estaba compuesto por 5 capas de Conv2D seguidas cada una de ellas por una capa de Max Pooling. Esta parte del modelo nos permitiría analizar los píxeles en sí mismos, pero era necesario hacer un análisis temporal para detectar no sólo las imágenes sino también las acciones. Por ello, era necesario introducir una capa Recurrente al final de estas capas Convolutivas. Teniendo en cuenta esta necesidad de realizar un análisis temporal, se introdujeron dos capas LSTM a la salida de la última capa Max Pooling (después de introducir una capa Flatten entre estas dos capas para adaptar los datos a la entrada que necesitaba el LSTM), y a éstas les siguió una Softmax que llevaría la clasificación del vídeo entre el hurto y la situación normal. Algo que cabe mencionar del modelo es que, para introducir los datos correctamente en el LSTM, es necesario convertir las capas Convolutiva y Max Pool en capas distribuidas en el tiempo. Esto es, permitir procesar en paralelo cada uno de los cuadros a través de esas capas en lugar de introducir todos los cuadros uno tras otro en las capas Convolutivas, y así insertar en el LSTM la secuencia de esos cuadros que componen un solo vídeo en lugar de cuadros individuales. Esta estructura se muestra en la siguiente figura:

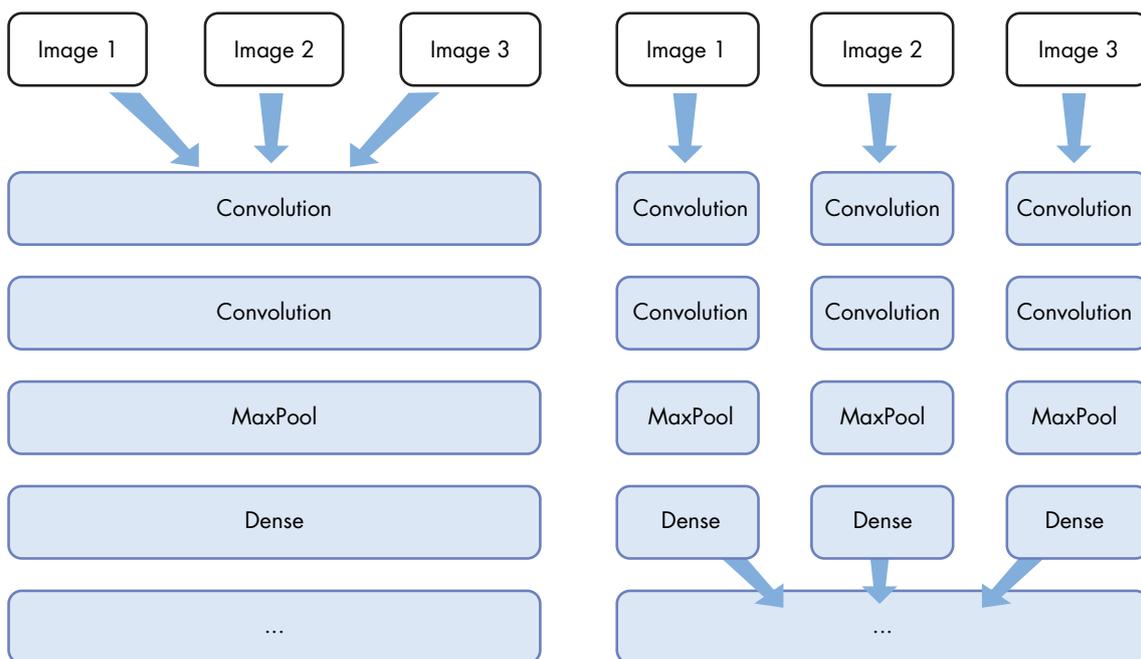


Figura 3. Capas no temporalmente distribuidas (izquierda) vs. Capas temporalmente distribuidas (derecha)

El modelo inicial que se describió anteriormente es el siguiente:



Figura 4. Modelo inicial



Este modelo fue modificado varias veces, cambiando los valores de sus hiperparámetros e incluso introduciendo una capa extra de Convolutional + Max Pooling, pero aun así no se encontró ningún aprendizaje en la red. Después de unas 300 épocas, el siguiente gráfico de pérdidas se generó en 30 épocas extra utilizando los pesos obtenidos en el entrenamiento anterior en el último modelo generado:

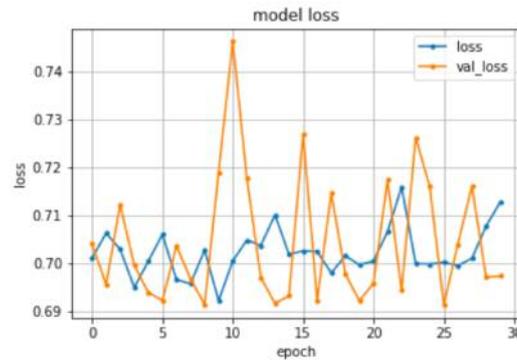


Figura 5. Resultados de las pérdidas de las épocas

Como puede verse en la gráfica, la pérdida de conjuntos de entrenamiento y validación oscila y no sigue una tendencia positiva. Al analizar la precisión de la validación en cada época, el modelo opta por afirmar que todos los vídeos son normales o que se trata de robos en tiendas, dependiendo de la época. Esto puede afirmarse ya que la precisión del modelo es la misma que la proporción de vídeos normales/de hurto presentes en el conjunto de datos. En el conjunto de pruebas, el modelo sigue esta misma lógica, como puede verse en la matriz de confusión que se muestra a continuación:

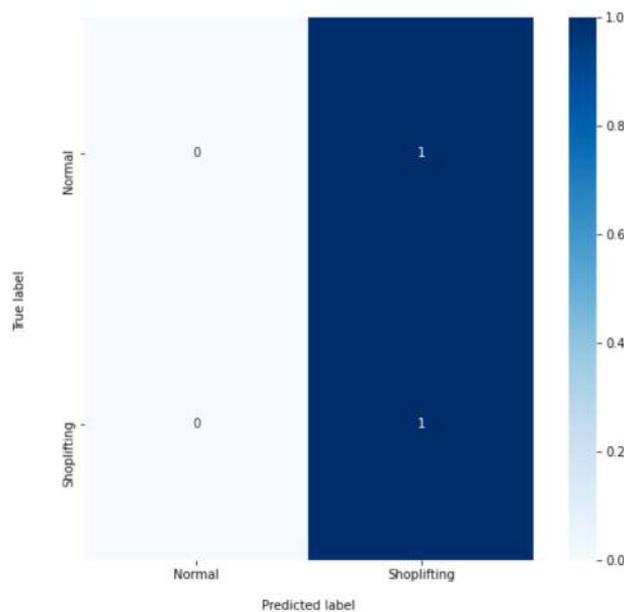


Figura 6. Matriz de confusión del conjunto de entrenamiento

3. CONCLUSIONES

Como se muestra arriba, los resultados están lejos de ser los ideales. En consecuencia, hay algunos cambios que podrían mejorar el rendimiento de los modelos. Se puede hacer un mejor análisis de hiperparámetros para encontrar un mínimo donde el modelo pueda aprender los datos de entrenamiento. El segundo problema principal es la falta de datos, que es un elemento clave que aumentará la eficiencia del modelo. Además, el modelo debe ser más guiado, esto puede lograrse mediante el preentrenamiento del modelo con una red neuronal que rastree los puntos clave de las personas en cámara, de esta forma será más fácil para el modelo aprender acciones que podrían implicar el robo en tiendas. Además, podría ser útil detectar los objetos y seguirlos como otra línea de acción. Con estos nuevos pasos los resultados deberían ser mejores.

En conclusión, es importante tener en cuenta el avance y el crecimiento de este complejo proyecto. Como se explica a lo largo del documento, hay aún trabajo por delante. A pesar de los diferentes obstáculos que ha tenido el proyecto, es crucial persistir y creer que es posible lograr el objetivo final. Este equipo es extremadamente consciente de "cómo desarrollar el trabajo", en lugar de llegar a cualquier accidental o fortuito. Así, el trabajo paso a paso dará el resultado esperado.

▶ VISIÓN ARTIFICIAL: RECONOCIMIENTO DE AUDIO CON CNNs ◀

1. INTRODUCCIÓN

El objetivo de este proyecto es desarrollar y entrenar técnicas de vanguardia para la clasificación de audio en el contexto de detección de robos y comodidad de usuarios. Esta solución se propone como complemento de las cámaras y alarmas habituales, posicionándose como un medio más de detección de anomalías y posibles situaciones de riesgo para los usuarios y clientes de estas alarmas.

La motivación del proyecto viene del hecho de que los expertos en seguridad han notado que las cámaras funcionan bien y hacen un gran trabajo detectando intrusos y robos, sin embargo, los delincuentes son cada vez más conscientes de estos sistemas y saben cómo evitar los campos de visión de las cámaras. También se han dado cuenta de que muchos de estos robos que no se detectan con la cámara, podrían haberse evitado fácilmente detectando y clasificando los sonidos que se produjeron durante el robo.

Para esta primera versión de nuestra solución y teniendo en cuenta los diferentes tipos de datos que tenemos, seleccionamos las siguientes clases para nuestros modelos de clasificación: vidrios rotos, llanto, ladridos de perro, fuego, disparos, puertas, pasos y otros. El modelo es realmente versátil en términos de clases, ya que algunas de ellas son útiles sólo cuando la alarma está apagada, otras cuando está encendida, para tranquilidad del usuario, y otras son útiles en ambos casos.



2. ESTADO DEL ARTE

La clasificación de audio siempre ha sido uno de los principales desafíos para la inteligencia artificial. Muchos algoritmos y técnicas de inteligencia artificial tratan de imitar la forma en que los humanos manejan o perciben la información. Sin embargo, el sistema auditivo humano es uno de los más complejos de entender y esto se traduce en una dificultad añadida para desarrollar las técnicas de inteligencia artificial.

Lo primero a entender sobre este proyecto es la base de este, que es como representar los sonidos que percibe el mismo oído humano. La mejor representación de este para analizar los datos no es la auditiva, sino la visual, a modo de gráfica. Los sonidos pueden ser representados de diversas formas, siendo la más simple la amplitud en el tiempo. Esto se debe a que el sonido puede definirse como una secuencia de vibraciones que varían la presión de las partículas en un medio, por lo que se suele usar la amplitud para representarlos, como se puede observar en la Figura 1.

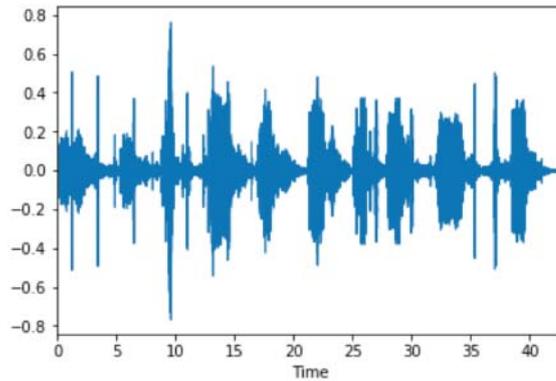


Figura 1: Representación temporal de una onda de audio

Una manera simple de tratar la amplitud en el tiempo es usando la transformada de Fourier, la cual permite trabajar en el dominio de las frecuencias en vez del tiempo. Usando esta simple formulación, se puede representar la magnitud de onda normalizada sobre la frecuencia. Ahora bien, para simplificar el análisis se parte el gráfico de amplitud sobre tiempo en pequeñas partes y se aplica la transformada de Fourier sobre cada una de ellas.

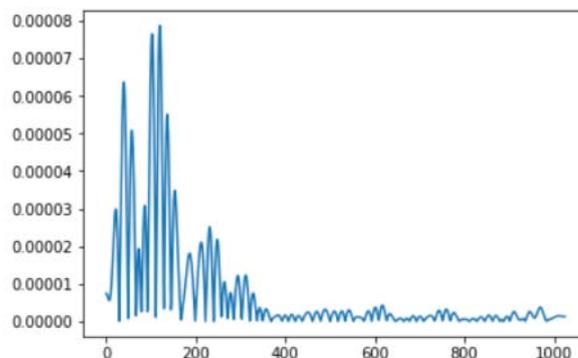


Figura 2: Representación de una onda sonora usando la transformada de Fourier

Con toda esta información se procede a representar cada parte en serie en una gráfica de frecuencia sobre tiempo, representando a su vez los dB (unidad que se utiliza para expresar la relación entre dos valores de presión sonora, o tensión y potencia eléctrica) en una escala de color.

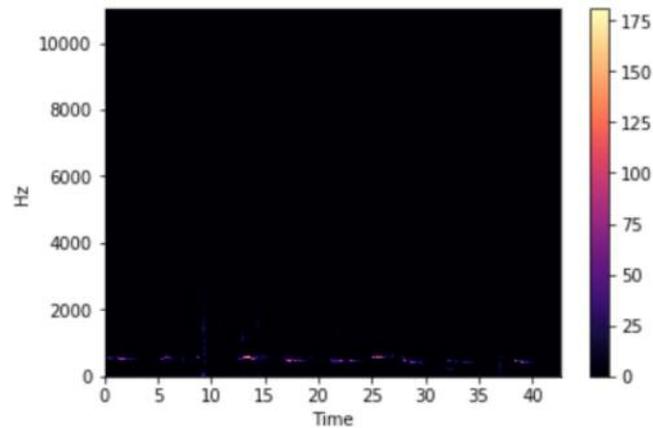


Figura 3: Representación en decibelios del diagrama de frecuencia de una onda sonora

El problema es que, para tener una representación en la que se vean más detalles sobre la información del sonido representado, se tiene que usar una escala logarítmica tanto en la representación de la frecuencia como la de los dB. A esto se le llama espectrograma (ver Figura 4).

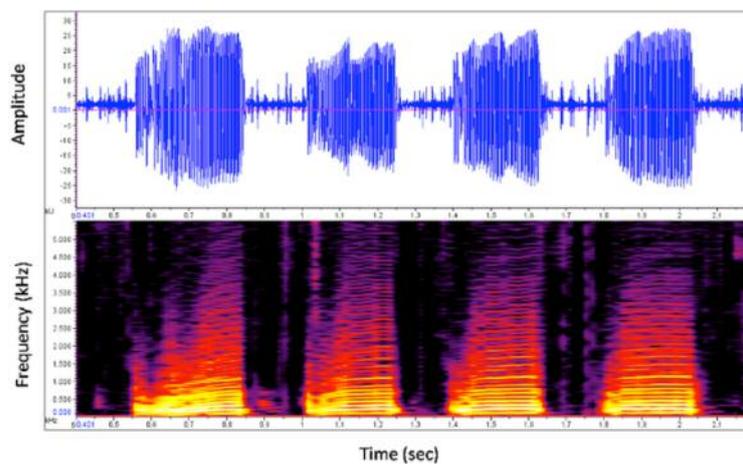


Figura 4: Representación de una onda sonora en escala logarítmica

El revés de esta representación es que, para altas frecuencias y altos decibelios, la diferencia en la representación es prácticamente imperceptible, por lo que le resultará más difícil a la red neuronal analizar y aprender de estos datos. Es aquí donde entra en juego la escala de Mel, la cual, desde un punto de vista matemático, es el resultado de aplicar una transformación no lineal a la escala de frecuencias, haciendo más obvias las diferencias a altas frecuencias, frente a lo que ocurría en la escala logarítmica [1].

Para aplicar este concepto, se pasa a la escala de Mel cada parte antes dividida del sonido representado en el dominio de las frecuencias y se continúa aplicando los mismos pasos que al utilizar la escala logarítmica común, dando resultado al espectrograma de Mel (ver Figura 5).

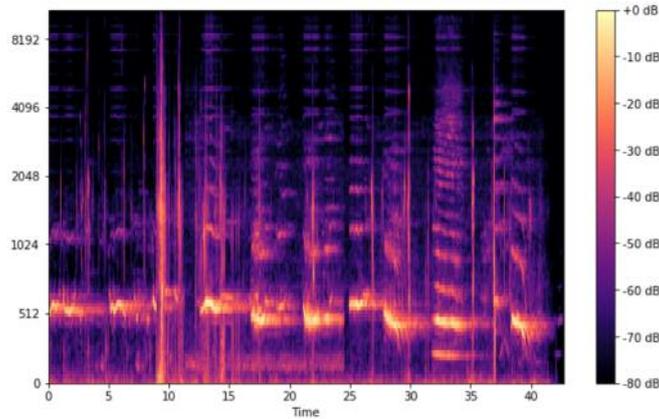


Figura 5: Representación del espectrograma de Mel de una onda sonora

Los espectrogramas de Mel suponen la conversión de la onda sonora en imágenes, lo cual nos permite poder emplear técnicas de clasificación de imágenes, que es uno de los campos más robustos y en los que se han logrado mayores avances en la inteligencia artificial. Las distintas técnicas recogidas en el estado del arte, en lo que a clasificación de audio se refiere, emplean los espectrogramas de Mel como *input*. La técnica principal, al igual que con la clasificación de imágenes convencional, son las redes convolucionales [2].

Una variante de los modelos de redes neuronales convolucionales, que también se aprovecha de la capacidad de usar imágenes para la clasificación de audio, han sido los *encoder*. Un *encoder* de imágenes es un sistema que tiene una imagen como *input* y aplica una serie de filtros convolucionales hasta sacar como *output* un vector que condensa la información importante de la imagen de entrada. Estos vectores característicos de salida del *encoder* pueden ser usados como entrada para una red neuronal de "fully connected layers" que actuarán como clasificador. Esta técnica ha generado algunos de los mejores resultados en la clasificación de audio debido a su gran flexibilidad para ser aplicados usando "transfer learning" con redes pre entrenadas [3].

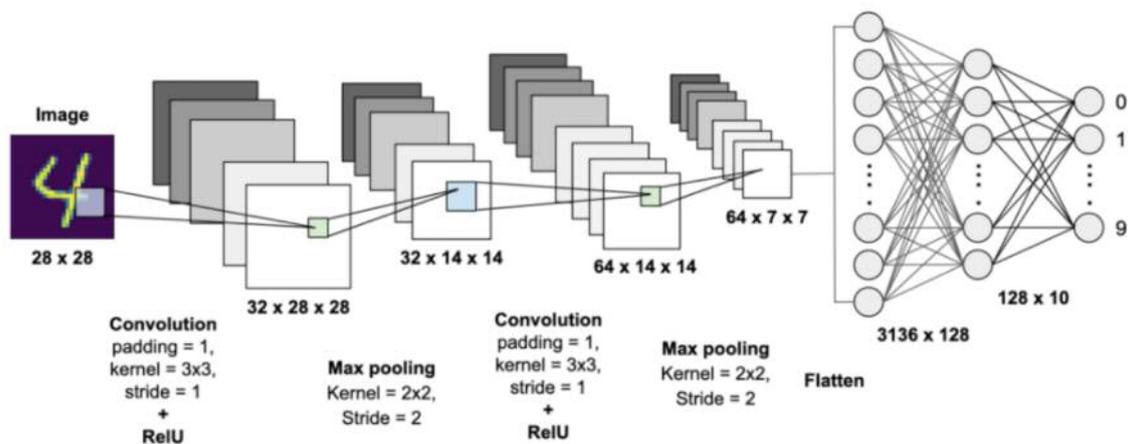


Figura 6: Estructura de una red convolucional para clasificación de imágenes

3. METODOLOGÍA

Para resolver el problema, se compararon dos técnicas de última generación relacionadas con las redes neuronales convolucionales bidimensionales (2DCNN). En primer lugar, una CNN entrenada desde cero con la estructura típica de este tipo de redes con varias capas ocultas formadas por una secuencia de capas convolucionales, más la activación y el *max-pooling*. El objetivo de este método es aprovechar la fiabilidad de la 2DCNN en la clasificación de las imágenes. Para ello el audio transformado en imágenes mediante la técnica del espectrograma Mel. Son estas imágenes las que la red tiene la función de clasificar. Nos referiremos a este método como el "Método 2DCNN" a lo largo de este documento.

El segundo método implementado consiste en utilizar el aprendizaje por transferencia aprovechando "vggish". Vggish es un modelo entrenado por Google en un conjunto de datos de más de 8 millones de sonidos extraídos de vídeos de youtube. La arquitectura de este modelo se basa en la famosa red convolucional VGG, a la que se han eliminado las capas finales orientadas a la clasificación y en su lugar la salida es un vector característico de cada audio. Esto hace que funcione como un codificador de audio. Posteriormente, se ha entrenado una red neuronal densa en este modelo, que toma este vector de salida "vggish" como entrada y devuelve un vector con la clasificación en una de las diferentes clases como salida. Este método se denominará "Método EMBEDDING".

Para ambos métodos se decidió utilizar el mismo tamaño de entrada para las imágenes, de modo que ambos fueran fácilmente comparables. Para ello, los audios se muestrearon a intervalos de 960 milisegundos, y con una ventana de 25 milisegundos con saltos de 10 milisegundos para calcular los espectrogramas de Mel. Estos parámetros se eligieron en base a los utilizados para el codificador pre-entrenado, que marcó las directrices a la hora de elegir el formato para procesar los datos de entrada.

3.1. Recopilación de datos

El primer punto fue identificar las diferentes categorías que se iban a reconocer. Estas clases son: vidrios rotos, llanto, ladridos de perro, fuego, disparos, puertas, pasos y otros (con el orden en inglés: broken glasses, crying, dog barks, fire, gunshots, door slams, steps, others). La clase "otros" se compone principalmente de silencios y ruidos que se consideran normales en un entorno de una vivienda en situaciones del día a día, como pueden ser ruidos de pajaros, obras o gente hablando.

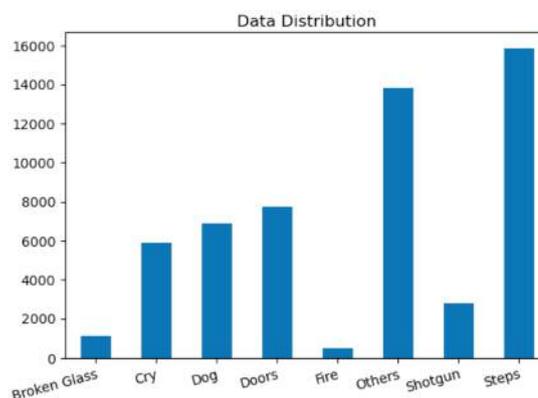


Figura 7: Distribución de las clases del dataset

Debido a que se necesitaban muchos audios para entrenar y probar el modelo, se seleccionaron varios sitios web para crear el conjunto de datos. La principal fuente de las grabaciones fue el conjunto de datos de UrbanSound (UrbanSound Dataset). Sin embargo, se necesitaba un preprocesamiento para obtener del conjunto de datos las clases especificadas anteriormente. Esto significa que se creó un



código para renombrar cada archivo de audio con su categoría específica. Además, se descargaron y pre procesaron el conjunto de datos Freesound (Freesound Dataset) y varios clips del sitio web de la BBC (BBC Dataset) para aumentar el número de audios y, en consecuencia, la precisión del modelo. Muchos de ellos eran algo ambiguos y tuvieron que ser clasificados manualmente para o bien eliminarlos o recortarlos y obtener mejores resultados.

Como puede verse en la Figura 7, el conjunto de datos está bastante desequilibrado, ya que se han reunido muchos audios de diferentes sitios web y todos tienen diferentes longitudes. Para tratar este problema se utilizó el atributo `class_weight` de la función `keras.model.fit` para penalizar más los errores cometidos por el modelo en las clases con ejemplos más bajos. El gráfico de la Figura 7 muestra la cantidad de datos después de cortar los archivos de audio en ejemplos de 960 ms y convertirlos en espectrogramas o vectores característicos, este proceso se explicará con más detalle en el próximo apartado.

3.2. Preprocesado del audio

Cuando nos dimos cuenta de que todo el proceso de entrenamiento estaba siendo ralentizando por el pre procesamiento de datos, el primer paso que dimos fue convertir todos los archivos de audio a los espectrogramas para el Método 2DCNN o a su correspondiente vector característico para el Método Embedding, y almacenarlos ambos en formato numpy (.npy). Después de que esta transformación se llevara a cabo se agilizó todo el proceso y los diferentes modelos pudieron ser entrenados más fácilmente.

Para convertir los audios en espectrogramas estos deben ser colocados en el directorio de wavfiles y dentro de él en el directorio correspondiente a su clase. Para ello, el código `convert_to_melspectrogram.py` convierte todos los audios a sus correspondientes espectrogramas y los almacena en el directorio de espectrogramas. En la Figura 8, se muestran algunos de los ejemplos de los espectrogramas Mel con su correspondiente representación temporal de audio.

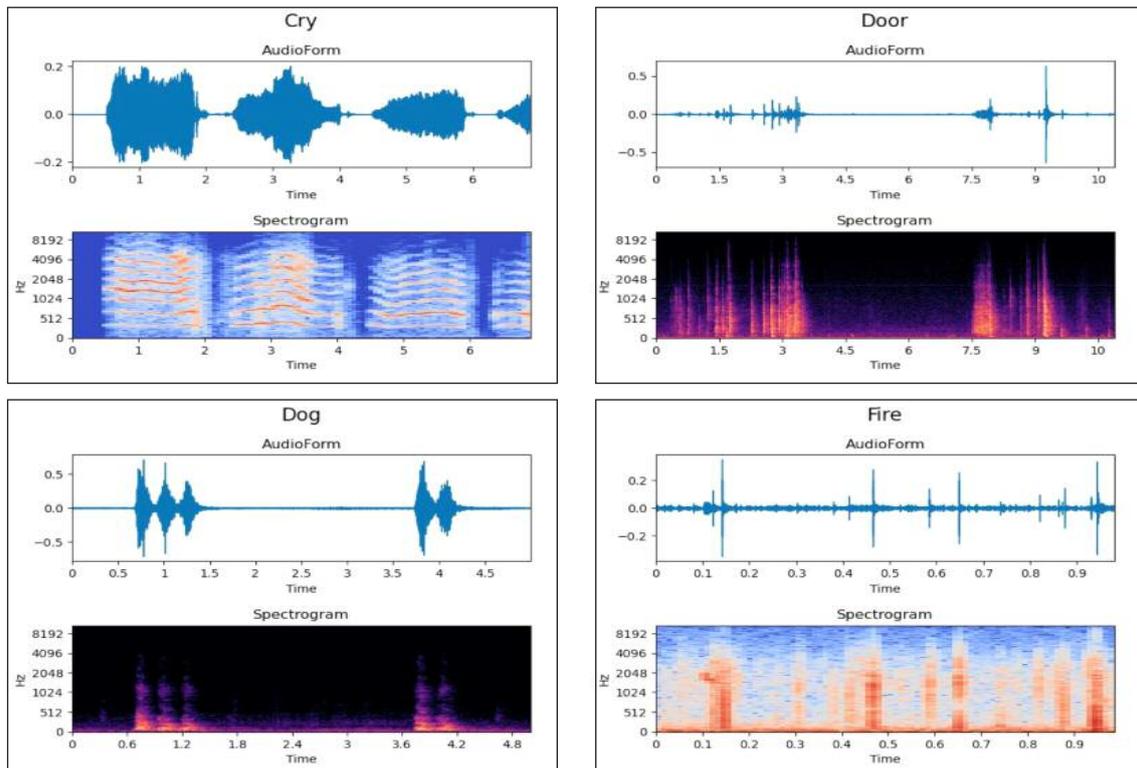


Figura 8: Ejemplos de espectrogramas de los audios de nuestro dataset

De la misma manera, para convertir los audios a los vectores característicos, estos se deben colocar en el directorio wavfiles y en el directorio correspondiente a su clase, entonces el código de generate_embeddings.py convierte todos los audios a su correspondiente vector característico y los almacena en el directorio de "embeddings" en un archivo .npy bajo su nombre de clase.

Hay otro código para el procesamiento de audio que es el ConvertMP3.py, que debe ser ejecutado en caso de que haya algunos audios .mp3 en el conjunto de datos que necesiten ser convertidos a .wav.

3.3. Modelos

Método 2DCNN:

Para este método se probaron 3 estructuras convolucionales diferentes, con distinto número de filtros y diferente tamaño de filtro en cada capa para ver cuál daba un mejor rendimiento. El trabajo posterior incluirá un estudio más extenso de los principales hiperparámetros para estos modelos, ya que sólo se realizaron pequeñas modificaciones con poca o ninguna alteración considerable de los hiperparámetros. Las tres estructuras diferentes pueden verse en el Anexo A.

Método EMBEDDING

El enfoque principal de este método proviene de "vggish", que es un codificador de audio entrenado por los investigadores de Google en una versión anterior de lo que más tarde se convirtió en el 8M Youtube Dataset. El modelo se basa en la famosa arquitectura convolucional VGG, pero se le hicieron algunos cambios para hacerlo apropiado para el problema de codificación de audio. Las principales novedades de este modelo son:

- El tamaño de entrada fue cambiado a 96x64 para los *inputs* convertidos a espectrogramas de Mel.
- El último grupo de capas convolucionales y max-pooling fue eliminado, por lo que el modelo consta únicamente de cuatro agrupaciones y no cinco.
- En vez de una capa densa de 1000 neuronas a la salida, se usa una de tan solo 128, que actúa como capa de codificación.

Nuestro enfoque consistió en tomar estos vectores de dimensión 128 y entrenar un clasificador en nuestras propias clases. Con este método también se entrenó a diferentes clasificadores para encontrar la mejor estructura y combinación posible de hiperparámetros. En la Figura 9 se muestra el espectrograma de un audio y en la Figura 10 se muestra un ejemplo de las diferentes imágenes generadas a partir de uno de los espectrogramas. Estas imágenes se generan con una longitud de 960 milisegundos y una superposición de 480 milisegundos entre una imagen y la siguiente, esto se hace de manera que toda la información pasa por la red dos veces y no se pierda nada o se produzca un mal corte de los datos.

Es importante notar que el principal problema que surge al hacer esto es que algunos audios son bastante largos y algunas de las imágenes de entrada generadas pueden no tener una zona característica o parte definitoria de la clase representada por el audio. Por ejemplo, en un audio de portazo, puede haber partes en las que no hay un sonido real de la puerta, sino sólo silencio o sonido ambiental previo al sonido de la puerta. Esto es lo que veremos más adelante en la matriz de confusión para los diferentes modelos, donde la mayoría de los errores provienen de este tipo de partes y los audios se confunden principalmente con la clase "pasos" y "otros".

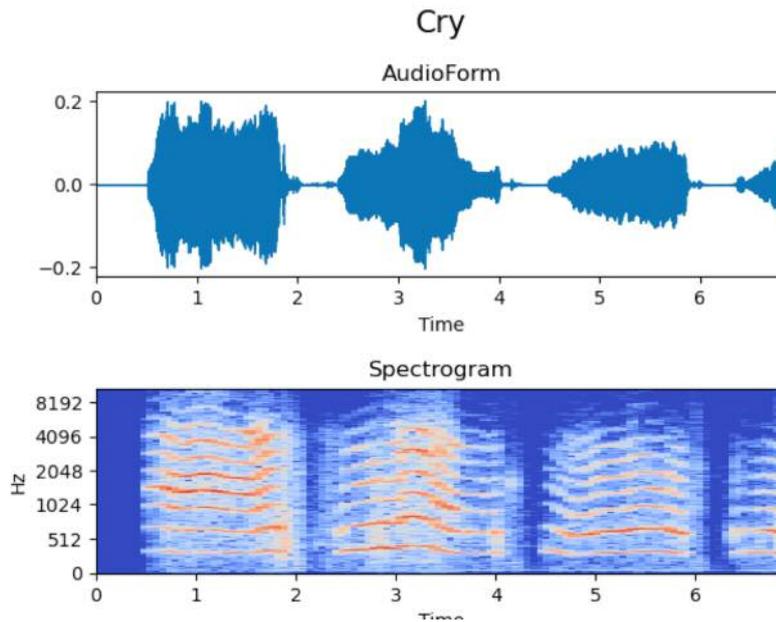


Figura 9: Ejemplo de espectrograma para una audio de la categoría "llanto"

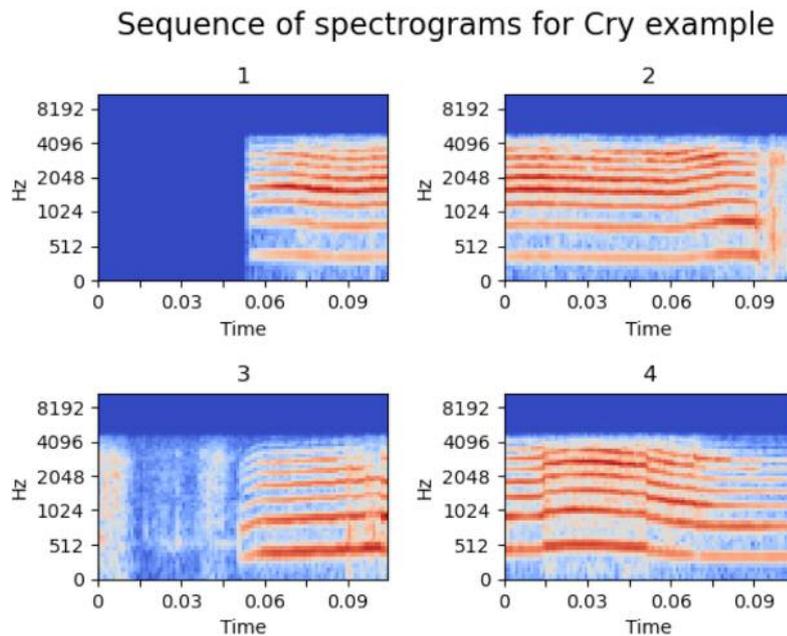


Figura 10: Secuencia de espectrogramas para la categoría "llanto"

3.4. Proceso de entrenamiento

Para ambos métodos se utilizaron algunas técnicas de regularización como el *Dropout*, o *Batchnormalization* para el método 2DCNN y *Early Stopping* para ambos. La ponderación de clases también se utilizó en ambas soluciones para tratar el tema de tener un conjunto de datos desequilibrado.

El proceso de entrenamiento se llevó a cabo en Google Colab, principalmente para utilizar el servicio de GPU que proporcionan para entrenar los modelos del método 2DCNN. Para el "Método EMBEDDING" no se necesitaba realmente una GPU para el entrenamiento, ya que una vez que todos los espectrogramas de audio se habían convertido a sus respectivos vectores de 128 elementos, ya no se ejecutaba ninguna arquitectura convolucional y todo el entrenamiento del clasificador podía realizarse fácilmente en una CPU.

Todos los entrenamientos se hicieron usando el optimizador Adam con una tasa de aprendizaje de 0.001 y una entropía cruzada categórica como función de pérdida para el modelo.

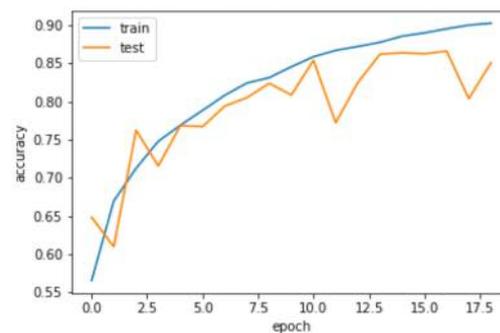
Los resultados de los diferentes modelos se pueden ver en el Anexo B. Para las 3 redes neuronales convolucionales y para el "Método EMBEDDING" tanto para el clasificador estándar como para el clasificador con las capas de "Dropout".

4. RESULTADOS

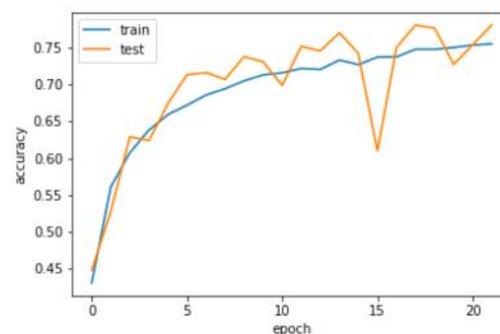
4.1. Método 2DCNN

Precisión

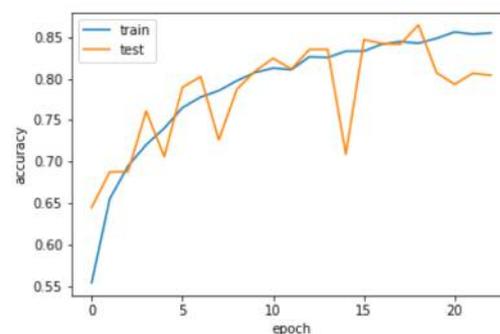
Model accuracy Conv2D_1



Model accuracy Conv2D_2



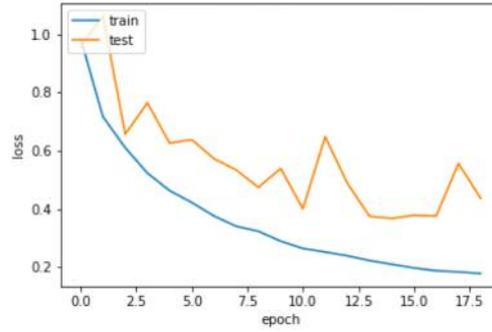
Model accuracy Conv2D_3



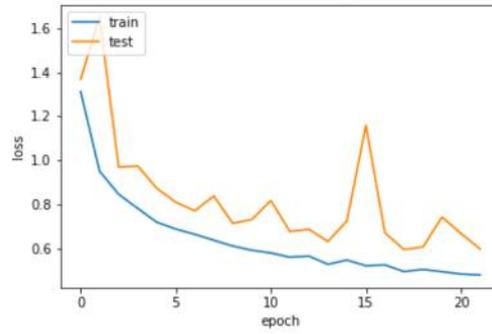


Pérdidas

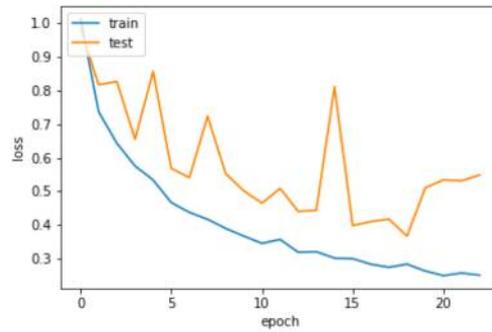
Model loss Conv2D_1



Model loss Conv2D_2

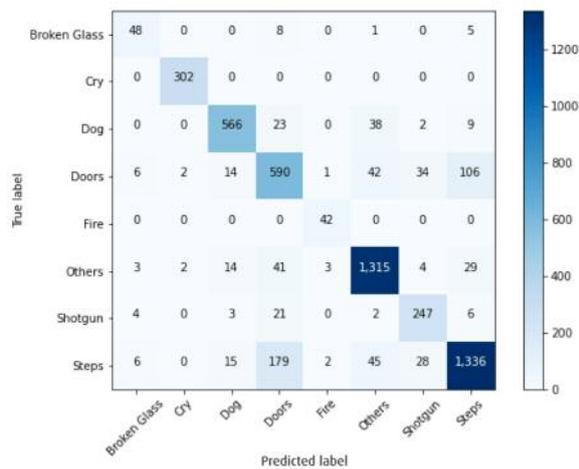


Model loss Conv2D_3

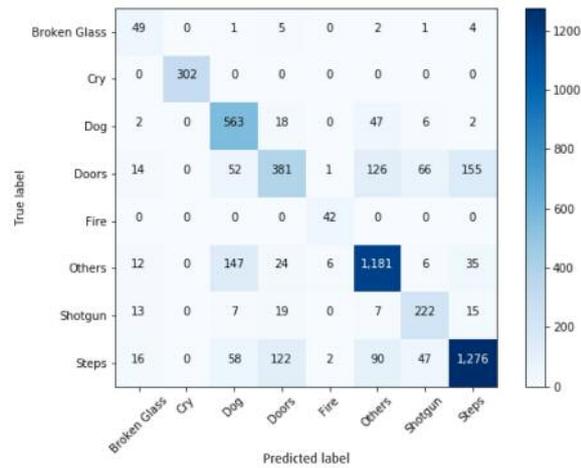


Matrices de confusión

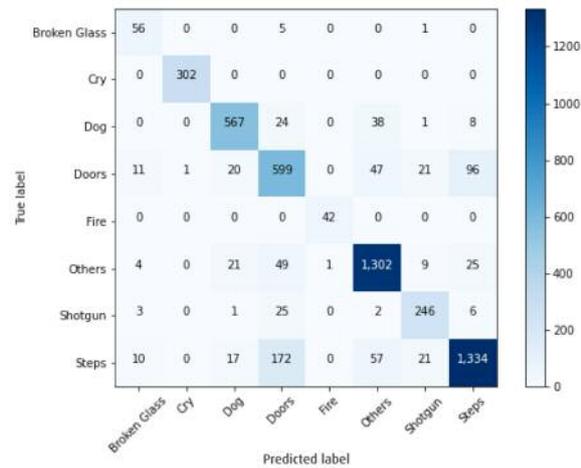
Confusion Matrix Conv2D_1



Confusion Matrix Conv2D_2



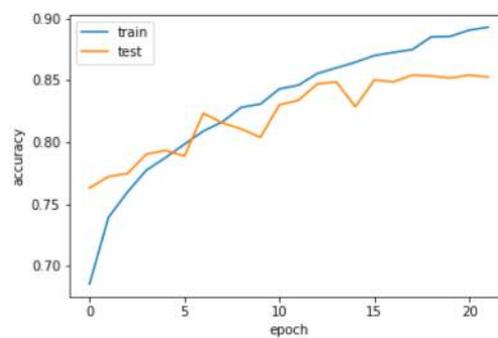
Confusion Matrix Conv2D_3



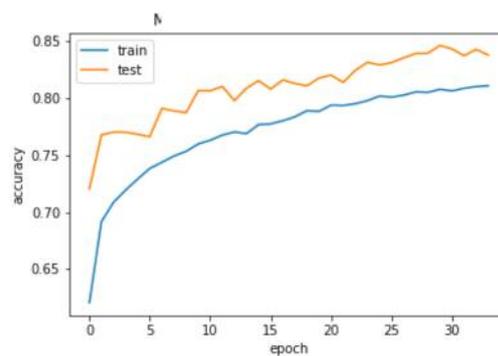
4.2. Método EMBEDDING

Precisión

Model accuracy Classifier



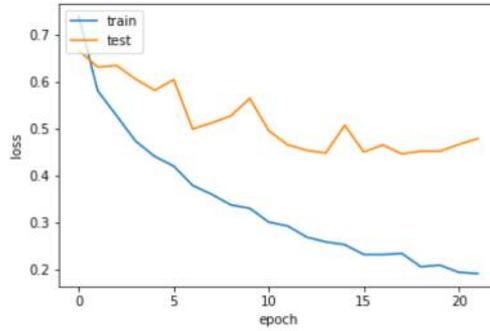
Model accuracy Classifier Dropout



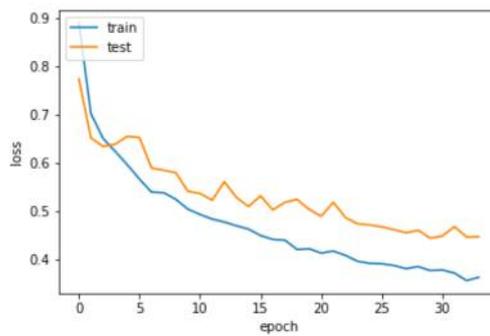


Pérdidas

Model loss Classifier

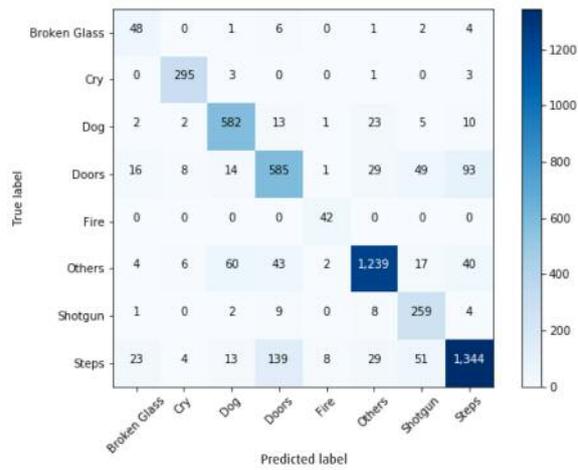


Model loss Classifier Dropout

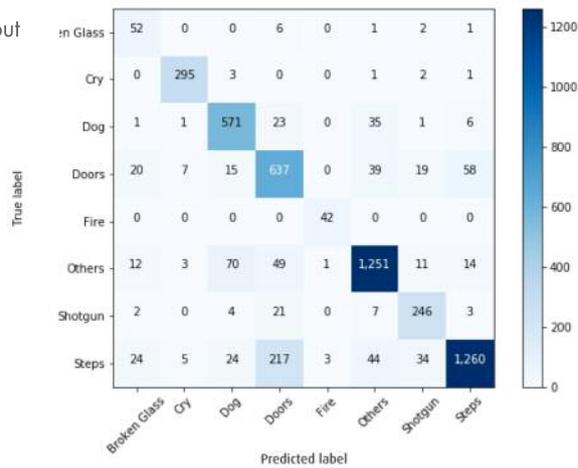


Matrices de confusión

Confusion Matrix Classifier



Confusion Matrix Classifier Dropout



4.3. Análisis de resultados final

En la tabla de resultados finales de cada modelo se puede inferir que el primer 2DCNN y el clasificador sin abandono dan los mejores resultados para este problema, con precisiones superiores al 85% en el conjunto de datos de la prueba. También es interesante observar las matrices de confusión mostradas arriba para cada modelo, donde notamos que los mayores errores en casi todos los modelos se cometen entre las clases "puertas" y "pasos".

FINAL RESULTS				
METHOD	ACCURACY (%)	LOSS	VAL ACCURACY (%)	VAL LOSS
2DCNN_1	88,567	0,210	86,394	0,368
2DCNN_2	75,558	0,478	78,168	0,596
2DCNN_3	84,293	0,285	86,491	0,368
Classifier	87,469	0,234	85,419	0,446
Classifier Dropout	80,776	0,377	84,639	0,445

Los mayores errores en cada modelo provienen del hecho de que estamos tratando los cortes individuales de cada archivo .wav como un solo ejemplo con su propia etiqueta. Esto funciona muy bien cuando la muestra contiene una parte característica del sonido que representan, sin embargo, cuando esta muestra no tiene ningún sonido sigue estando etiquetada como si fuera el sonido completo, pero esa parte individual puede estar más cerca de otra clase.

Un buen ejemplo de esto ocurre con la clase "puertas". En estas muestras hay muchos pequeños cortes del espectrograma que contienen una parte del portazo u otro sonido relacionado con la puerta, sin embargo, hay otros cortes que abarcan justo entre dos sonidos de puerta, pero que en realidad no contienen ningún sonido de puerta y por lo tanto se confunden con las clases "pasos" u "otros", a las cuales sí que pertenecen.

5. TRABAJO FUTURO

Las líneas de trabajo futuras relacionadas con este proyecto pueden incluir:

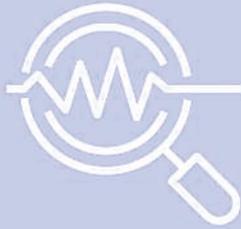
- Comparación del coste computacional de ambos modelos cuando se intenten implementar en un escenario real de funcionamiento. Mirar latencias y ver qué modelo funciona mejor al ser implementado.
- Probar nuevas arquitecturas (LSTM quizás) y buscar mejorar los hiperparámetros.
- Arreglar errores cometidos en el entrenamiento de los modelos debidos a la confusión creada al cortar los audios (lo explicado en el apartado de conclusiones).

6. BIBLIOGRAFÍA

- [1] D. Gartzman, «TowardsDataScience,» 19 Agosto 2019. [En línea]. Available: <https://towardsdatascience.com/getting-to-know-the-mel-spectrogram-31bca3e2d9d0>.
- [2] J. Salamon y J. P. Bello, «Deep Convolutional Neural Networks and DataAugmentation for Environmental SoundClassification,» *IEEE SIGNAL PROCESSING LETTERS*, 2016.
- [3] «Medium,» 6 Agosto 2018. [En línea]. Available: https://medium.com/@krishna_84429/audio-classification-using-transfer-learning-approach-912e6f7397bb.



• DESTREZA ROBÓTICA - GRUPO ANTOLIN



Alumnos:

Borja Rojo,
Isabel Ugedo,
Daniel Horcajo,
Marcos Ventosa
Lixiang Dong



1. INTRODUCCIÓN

El objetivo de este proyecto es implementar un sistema para seleccionar componentes específicos y llevarlos a la línea de montaje. Estos componentes se seleccionarán con reconocimiento de imagen de cajas que contienen diferentes elementos. El prototipo empleará un robot YuMi (ABB) con pinza y ventosa para trasladar los componentes.

Para la selección del mejor agarre de cada pieza se utilizarán las bases de datos y redes neuronales entrenados de Dex-Net, un proyecto de Berkley.

Finalmente, será necesario emplear una cámara de profundidad (RGB-D) para capturar la forma de los objetos y estudiar los posibles agarres. Para interactuar con el robot se usará la librería de Python Yumipy.

2. DESCRIPCIÓN DE DEX-NET

Con Dex-Net se consigue generar de forma masiva *datasets* que asocian nubes de puntos y agarres con una etiqueta de robustez binaria. Estos *datasets* son usados para entrenar después un GQ-CNN, como se comenta en el siguiente apartado. Los *datasets* de Dex-Net han ido aumentando y han sido refinados a lo largo de las distintas iteraciones del proyecto.

Las bases de datos que usa se usan en Dex-Net son HDF5 (Hierarchical Data Format 5).

El código de Dex-Net permite abrir/leer/escribir y con esto permite:

- Enseñar objetos de la base
- Enseñar los agarres asociados a un objeto
- Enseñar poses estables de un objeto
- Exportar los objetos a un .obj
- Muestrear los agarres para los objetos

3. DESCRIPCIÓN DEL ALGORITMO GQ-CNN

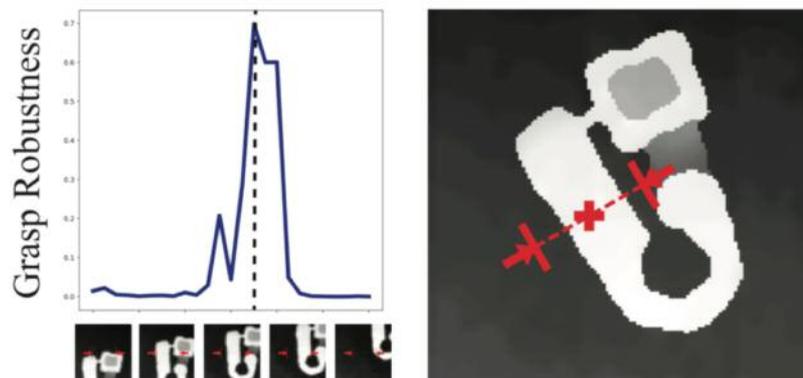
El objetivo de la red neuronal GQ-CNN es evaluar los candidatos de agarre para ser capaz de seleccionar el que tenga mayor probabilidad de éxito en agarrar, levantar y transportar el objeto. Para ello, GQ-CNN se entrena con los datos de Dex-Net, que son objetos asociados a posibles agarres, como se ha comentado anteriormente.

El primer paso es procesar la imagen de profundidad enviada por la cámara, y usarla para proponer candidatos de agarre.

Cada agarre está compuesto por dos puntos de contacto. A partir de estos puntos, QG-CNN tiene lógica para calcular la orientación de la pinza y para comprobar que no hay colisiones en el recorrido.

Para obtener los candidatos de agarre, se utilizan *samplers*. Dex-Net incluye diferentes *samplers*, siendo los principales para pinza *Cross-Entropy Method (CEM)* y *Antipodal*, y los de ventosa *Suction* y *Multisuction*.

El *Antipodal sampler* utiliza *edge-detection* para mapear los bordes del objeto. Entonces, selecciona dos píxeles de bordes paralelos, y comprueba que cumplan las condiciones de agarre válido. Estos requisitos son principalmente que el agarre sea paralelo a la superficie de apoyo del objeto y que el ancho del agarre no supere la amplitud máxima de la pinza del robot. Este proceso se repite de forma iterativa a través de todo el objeto, como muestra la siguiente imagen. Los píxeles se eligen de forma aleatoria, lo cual no es ideal. Finalmente se evaluará la robustez del conjunto de candidatos para seleccionar el mejor.



Edge detection during antipodal grasp planning

La siguiente gráfica se obtiene al realizar un barrido de los candidatos de arriba a abajo. Como se puede ver, la robustez es escasa con picos en zonas de agarre muy concretas. Esto hace que sea difícil encontrar la zona de agarre óptimo muestreando de forma aleatoria, por lo que es mucho más eficiente usar un método como CEM.

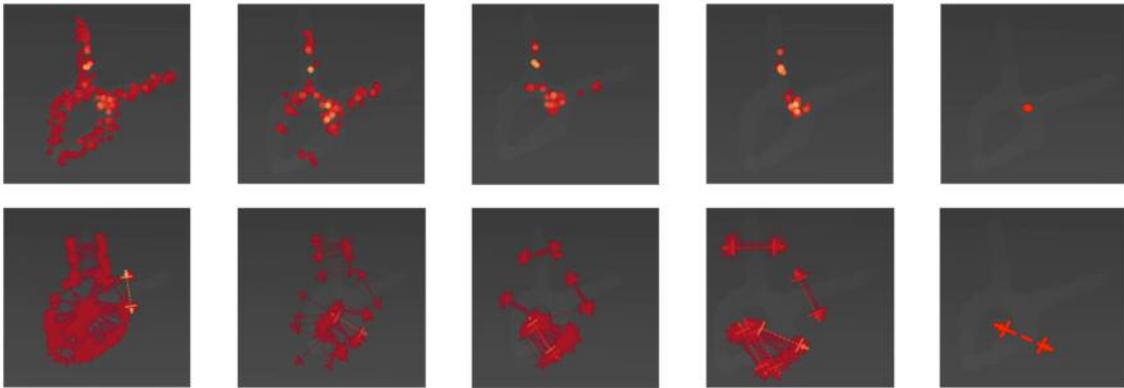
CEM es un método iterativo que optimiza la búsqueda de un agarre robusto. CEM permite predecir dónde se encuentran estos picos de robustez en la pieza. Sus iteraciones convergen en la zona exacta. Un pseudocódigo aproximado del algoritmo puede ser el siguiente:

- 1) Muestrear un conjunto de agarres candidato iniciales
- 2) Ordenar los candidatos en función de su robustez (con el GQ-CNN)
- 3) Ajustar un GMM (modelo de gaussianas) al X% de los mejores candidatos
- 4) Re-muestrear a partir del GMM
- 5) Repetir los pasos 2 y 4 durante K iteraciones
- 6) Devolver el mejor candidato



Los *samplers* de ventosa son muy sencillos, ya que se limitan a buscar una superficie plana y suficientemente grande, así como un punto cercano al centro de gravedad del objeto.

Utilizando los ejemplos de objeto incluidos en Dex-Net, hemos sido capaces de mostrar el proceso de muestreo y de selección de agarre definitivo (CEM). Se incluye a continuación:



Dex-Net implementa dos métodos para evaluar la calidad del agarre, *Force Closure* y *Ferrari-Canny*. Ambos devuelven índices diferentes, que se pueden calcular en modo *Robust Static* o *Robust Quasi-Static*. La diferencia es que *Static* asume que se conocen con seguridad las posiciones de la pinza y el objeto.

Quasi-Static, en cambio, incorpora un grado de incertidumbre, que se puede especificar. En función del número de fuentes de incertidumbre, se calcularán las métricas *Force Closure* y *Ferrari-Canny* *n* veces según una distribución gaussiana. En este caso las métricas tienen un rango de entre 0 y 1, por lo que se habla de **probabilidad** de éxito.

La salida de GQ-CNN es un objeto de la clase *GraspAction*, que incluye una imagen 2-D del agarre así como una probabilidad de éxito. Existe además un método para transformar esta imagen 2-D en coordenadas 3-D para el brazo robótico (clase *ParallelJawPtGrasp3D*).

4. YuMi

El robot YuMi, de ABB, incorpora dos brazos en los que se pueden instalar diferentes tipos de *grippers* o pinzas de agarre. Algunas de las diferentes opciones disponibles en el mercado son:

- Pinzas paralelas (originales de ABB), con opción de adición de una ventosa de succión
- *Gripper* personalizado impreso en 3D
- *Gripper* tipo tentáculo



Ilustración 1- Tipos de gripper existentes para el robot YuMi.

Debido a su facilidad de uso, así como a su versatilidad y adecuación a las diferentes piezas que el robot deberá agarrar, la elección realizada es aquella del agarre en paralelo.

Con dicho agarre, cada brazo tiene capacidad de levantar 20N, es decir, alrededor de 2 kg. Dado que la pinza pesa aproximadamente 0.5 kg, encontramos una limitación a objetos de 1.5 kg.

Un parámetro importante en el funcionamiento del robot es la presión de agarre. Debe ser suficiente para que el objeto no deslice, así como limitada para no dañarlo. Las pinzas incorporan sensores de presión, por lo que podemos ajustar el valor de forma sencilla usando comandos de Yumipy.

La apertura máxima de la pinza es un parámetro ajustable, del que se va a prescindir. Se asumirá en el código de Dex-Net que la pinza se dispone en su apertura máxima, y se realizará en Yumipy el ajuste correspondiente.

5. PRINCIPALES PROBLEMAS

Actualmente las imágenes de la cámara funcionan correctamente. El único problema es que habría que ajustar la altura de la cámara y los parámetros internos del GQ-CNN para ajustarlos de forma precisa a nuestra propia cámara. Por otro lado, una vez instalada la cámara en el lugar de trabajo, habría que retocar los parámetros internos de la cámara (se comenta en el apartado Cámara de profundidad) para adecuar la imagen al entorno real de trabajo, y obtener imágenes más limpias de los objetos.

Finalmente, uno de los problemas que consumió más tiempo fue la instalación de Dex-Net en nuestros ordenadores. Se comenta en el apartado *Recursos* cómo reducir la dificultad del proceso de instalación. En cualquier caso, en los archivos adjuntos a este proyecto se incluye una máquina virtual de Ubuntu con GQ-CNN instalado.

6. RECURSOS

6.1. Código

6.1.1. Código de GQ-CNN [1]

Contiene lo necesario para entrenar y analizar la CNN que puntúa agarres de objetos (tanto agarre con pinzas paralelas como por succión).

Para descargar los GQCNN preentrenados y probarlos seguir la siguiente guía [2].

Para correr un GQ-CNN preentrenado contra una imagen propia y sacar el agarre más robusto se introduce el siguiente código en la consola. `python examples/policy.py GQCNN-3.0 --depth_image data/examples/single_object/primense/depth_0.npy --segmask data/examples/single_object/primense/segmask_0.png --config_filename cfg/examples/replication/dex-net_3.0.yaml`

Con esto se llama al archivo `policy.py` contenido dentro de `examples/`, el primer argumento es el GQCNN que se va a usar (puede ser el 2.0, 2.1, 3.0, 4.0 ...), el siguiente es la imagen de profundidad que sale de la cámara de profundidad (`--depth_image`), el siguiente es una máscara binaria con el objeto aislado (`--segmask`), esta máscara es opcional y en caso de no proporcionarse se calcula en `examples/policy.py`. El último argumento (`--config_filename`) es un archivo de configuración que se encuentra en `cfg/examples/replication/` y que se puede modificar de acorde a las necesidades.

Dentro del directorio `GQ-CNN/` podemos encontrar el core de GQCNN. Conseguir instalar GQCNN es relativamente asequible, pero puede haber muchos problemas con las versiones de Python.



6.1.2. Código de Dex-Net [3]

Contiene todo el código correspondiente a la base de datos, cómo añadir objetos a la base de datos, borrarlos, visualizarlos, visualizar sus poses estables y crear las imágenes de profundidad para entrenar posteriormente un GQCNN.

El core del código se encuentra en [src/dexnet/](#).

Conseguir instalar Dex-Net y que funcione es difícil y su dificultad depende de factores ajenos y por lo tanto cada instalación es un mundo.

6.2. Literatura

6.2.1. Papers de Dex-Net [4]

En esta página web se puede encontrar todos los papers de Dex-Net junto con pequeños *overviews* y algunos vídeos donde se pueden apreciar el desempeño en cada una de las iteraciones de Dex-Net, la lectura de los papers es muy densa y ardua, por lo que recomendamos empezar por el TFM del Imperial College.

6.2.2. TFM del Imperial College [5]

El objetivo de este TFM es conseguir usar Dex-Net para entrenar un GQCNN y una vez hecho esto, intentar mejorar Dex-Net.

Si se lee y se comprende este TFM, se pueden entender las principales partes de Dex-Net y GQCNN, incluyendo métodos de proponer nuevos agarres, el paso de un agarre en una imagen de profundidad vista desde la cámara a una posición en 3D respecto del sistema de coordenadas del Robot.

Una vez leído este TFM se puede intentar leer los papers de Dex-Net ya que será mucho más inteligible en este punto.

6.2.3. Documentación de GQCNN [6]

La documentación del código de GQCNN y cómo usarlo es algo escasa pero suficiente para que con algo de investigación en el código se pueda entender.

6.2.4. Documentación de Dex-Net [7]

La documentación del código de Dex-Net es algo pobre, el apartado de API DOCUMENTATION contiene las funciones implementadas.

7. CÁMARA DE PROFUNDIDAD

Para poder probar Dex-Net con imágenes y objetos propios, se utiliza una cámara de profundidad. Estas permiten conocer la distancia a la que se encuentra cada punto de la imagen respecto del dispositivo. En este caso, la GQCNN tiene como entrada una imagen de profundidad sacada de dicha cámara. Para poder insertar la imagen en la red neuronal, será necesario ajustarla a un formato concreto, como se comenta más adelante.

7.1. Hardware

Para este proyecto, se ha aprovechado la cámara que estaba en la escuela, la Intel Realsense D435.

Manufacturer:	Intel
Type:	Housed Camera
Depth Technology:	Active IR Stereo
Horizontal Resolution:	1280
Vertical Resolution:	800
Shutter Type:	Global shutter
FOV Horizontal:	87
FOV Vertical:	58
FOV Diagonal:	95
Max. Depth Frame Rate at full resolution (fps):	30
Max. Depth Resolution:	1280 x 720
RGB Sensor:	Yes
Max. RGB Resolution:	1920 x 1080
Max. RGB Frame Rate at full resolution (fps):	60
Interface:	USB3.0
Baseline (mm):	50
Minimum Depth Distance (mm):	200
Maximum Range:	10m+
Package:	Starter Kit

Tabla 1: Especificaciones de la cámara

Es una cámara alimentada a través de un puerto USB que incluye sensor de profundidad y RGB. Como se puede ver en las especificaciones, la distancia mínima es de 200 mm, y la máxima, de 10 metros, por lo que se ajusta a las condiciones del trabajo del robot.

7.2. Software

Para utilizar la cámara se ha empleado el software propio de Intel "Depth Quality Tool for Intel RealSense Cameras"¹, así como scripts en Python, haciendo uso de las librerías RealSense² (propia de la cámara) y OpenCV³.

1 <https://github.com/IntelRealSense/librealsense/tree/master/tools/depth-quality>

2 <https://pypi.org/project/pyrealsense2/>

3 <https://opencv.org/>



El software de Intel permite realizar un calibrado inicial de los parámetros internos de la cámara, como exposición, ajuste de brillo, blancos, ganancias, etc.... Estos parámetros son importantes ya que alteran la calidad de la imagen y, por lo tanto, influyen en el resultado de la GQCNN. Toda esta configuración se exporta a un archivo `.json`, para su posterior implementación en nuestro propio código.

La librería RealSense es propia de Intel y permite acceder desde código a todos los parámetros de la cámara de profundidad, así como acceder a las imágenes que la misma está tomando. Además, incluye funciones de post-procesado que serán importantes a la hora de tomar la imagen de profundidad.

Finalmente, la librería OpenCV es una librería específica para visión artificial. En este proyecto se ha utilizado especialmente con fines auxiliares para la visualización de las imágenes en pantalla. Además, incluye funciones rápidas que permiten modificar parámetros de las imágenes de forma cómoda.

7.3. Desarrollo del trabajo

En primer lugar, tras instalar el software de Intel, se intentó tomar una foto directamente haciendo uso de un código en Python, las imágenes obtenidas presentaban un nivel alto de ruido. Se intentó configurar los parámetros de la cámara uno a uno desde el código, pero debido a problemas con la librería RealSense en Python, se decidió probar a utilizar C++ en su lugar. En el código de C++ (hecho a partir de un código modificado de los ejemplos propios de Intel) la imagen mejoraba levemente, pero no lo suficiente, y debido a la cantidad de parámetros a ajustar dentro de la cámara, se concluyó como inviable realizar dicho proceso de ajuste de parámetros uno a uno desde código.

Para solucionar este problema, se utilizó el software propio de Intel, el cual permite modificar los parámetros en directo desde la aplicación, y exportar esa configuración en un archivo de extensión `.json`. Cabe destacar que este archivo tan solo guarda la configuración de los parámetros de la cámara, y no el postprocesado que es posible realizar en el software de Intel; esto deberá hacerse posteriormente a mano. A partir de este punto, simplemente es necesario importar dicho archivo de configuración en el script de Python para cargar los parámetros de la cámara. Es recomendable, además, hacer un estudio de los distintos filtros disponibles de cara a limpiar la imagen.

Otro de los problemas que surgieron fue el formateo de la imagen de entrada a la GQCNN, ya que al intentar introducir la imagen de profundidad directamente esta es obtenida de la cámara y produce errores. En primer lugar, hay que asegurarse de que la imagen tiene una resolución de 640x480 píxeles. El siguiente paso es convertir los valores de los píxeles a distancia en metros: para ello, se utilizó la escala de profundidad propia de la cámara y, posteriormente, hay que convertir la imagen, que es del tipo `frame (pyrealsense)` a `array`, obteniendo un `array de strings`; a continuación, hay que realizar una conversión de `string` a `float32` (`float64` dará en GQCNN problemas de memoria RAM) y además convertir el `array2d` a un `array3d` (para que se vea reflejado el canal único de la imagen), por lo que la imagen pasa de (480, 640) a (480, 640, 1).

La imagen se guarda en formato `.npy`, y está lista para ser introducida en la GQCNN y obtener así un agarre.

Uno de los grandes problemas que pueden surgir al utilizar esta metodología de obtención de imágenes para la GQCNN es el hecho de que el modelo de cámara utilizado (Intel Realsense D435) tiene, a cortas distancias, un ángulo ciego que produce una franja vertical en la parte izquierda de la imagen, como se puede observar en la siguiente figura.

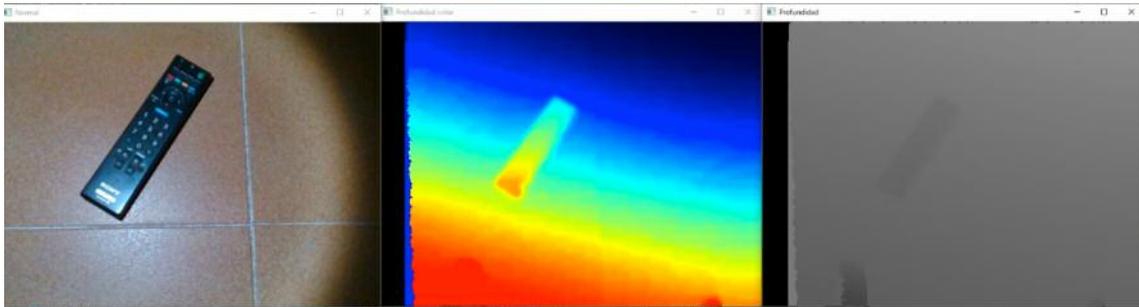


Ilustración 2- Ejemplo de punto ciego de la cámara.
Nótese la franja vertical negra situada a la izquierda en las imágenes de profundidad.

La principal consecuencia de esta franja es el hecho de que, al exportar la imagen de profundidad a un archivo .npy, obtenemos una zona repleta de ceros. Esto se traduce en que, al correr el algoritmo usando esta imagen, se obtenga como resultado una imagen casi completamente en blanco. Se muestra a continuación el resultado que se obtiene utilizando las imágenes proporcionadas como muestra, y el resultado obtenido debido a la franja.

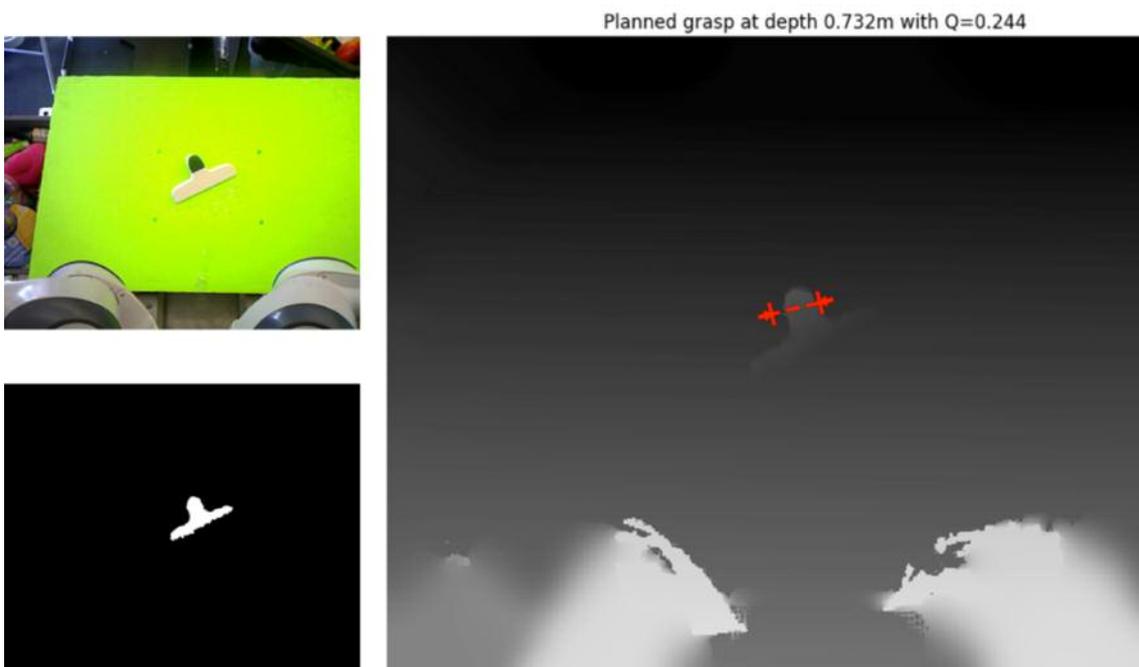


Ilustración 3- Resultado obtenido al utilizar uno de los ejemplos disponibles.

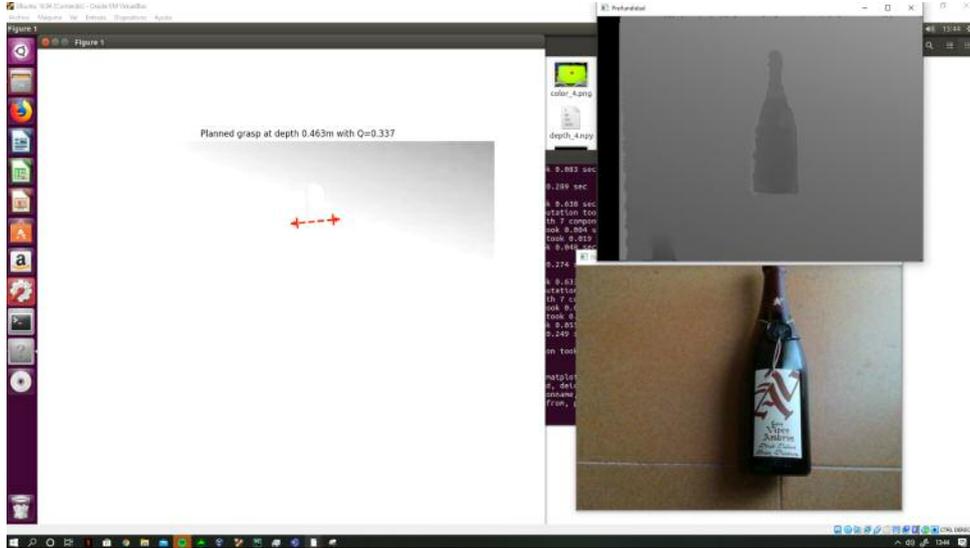


Ilustración 4- Resultado obtenido al utilizar una imagen propia.
Nótese que la franja negra hace que la imagen del grasp final esté casi completamente en blanco.

Tras un extenso análisis, se descubrió que esta franja, al ser completamente negra, hacía a la red pensar que el objeto a agarrar estaba constituido por la totalidad del resto de la imagen, y no solo por el objeto que realmente se quería agarrar. Para paliar este problema, se ha añadido la línea de código

```
depth_image[depth_image == 0] = depth_image.mean()
```

que sustituye los píxeles de valor cero por la media de los valores del resto de píxeles de la imagen. El resultado final es satisfactorio, obteniendo un *output* similar al de la imagen ejemplo.

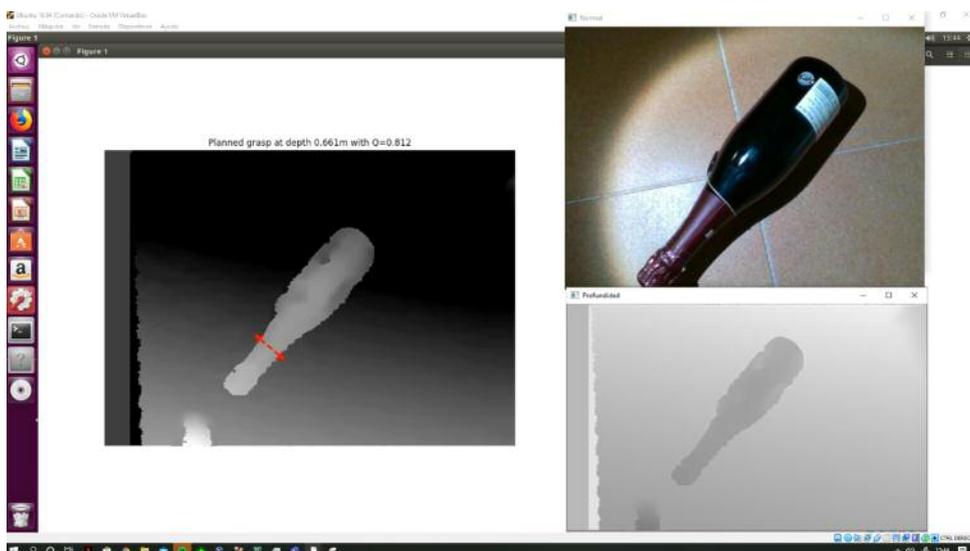


Ilustración 5- Resultado obtenido con una imagen propia y sustituyendo los ceros de la franja vertical por la media de los valores de los píxeles de la imagen.

7.4. Código de captura y tratamiento de imágenes

En primer lugar, se carga el archivo de configuración exportado desde el software de Intel:

```
jsonObj = json.load(open("Custom.json"))
```

Las siguientes líneas de código se encargan de inicializar la cámara, habilitando los sensores correspondientes.

Dentro del `while True:` se están obteniendo *frames* constantemente desde la cámara. Al principio, hay una función que se encarga de no enviar imágenes hasta que no se haya ajustado correctamente la exposición al iniciar la cámara, ajustando los *frames*.

El siguiente paso es aplicar los filtros de post-procesado⁴. En este caso, se aplican los que se vieron que afectaban más a la calidad de la imagen: "Hole filling filter" y "Spatial filter"; el primero para quitar ruido de la imagen, y el segundo para suavizar los bordes de los objetos. También se genera otro *frame* a partir del de profundidad, para aplicarle un mapa de color y facilitar la visualización posteriormente.

Antes de mostrar las imágenes por pantalla, se pasan a *arrays* y, además, las unidades de la imagen de profundidad son cambiadas a metros multiplicando por la escala de profundidad obtenida anteriormente a través de la línea de comando:

```
depth_scale = cfg.get_device().first_depth_sensor().get_depth_scale().
```

Finalmente, para guardar las imágenes se pulsa la barra espaciadora. En esta parte del código, la imagen de profundidad se convierte a float32 y se le añade la tercera dimensión (el que tenga un canal) al *array*, para que la GQCNN pueda leerla correctamente. Al pulsar la barra espaciadora, se guardan tanto la imagen en color y la imagen de profundidad en formato *.npy*, que será dado como argumento a la GQCNN.

8. REFERENCIAS

- [1] (<https://github.com/BerkeleyAutomation/GQ-CNN>)
- [2] (<https://berkeleyautomation.github.io/GQ-CNN/replication/replication.html>)
- [3] (<https://github.com/BerkeleyAutomation/dex-net>)
- [4] (<https://berkeleyautomation.github.io/dex-net/>)
- [5] (<https://www.imperial.ac.uk/media/imperial-college/faculty-of-engineering/computing/public/1819-ug-projects/SaporaS-Grasp-Quality-Deep-Neural-Networks-for-Robotic-Object-Grasping.pdf>)
- [6] (<https://berkeleyautomation.github.io/GQ-CNN/>)
- [7] (<https://berkeleyautomation.github.io/dex-net/code.html>)

4 https://github.com/IntelRealSense/librealsense/blob/jupyter/notebooks/depth_filters.ipynb



- TRADING EN MERCADOS DE *COMMODITIES* - REPSOL

Alumnos:

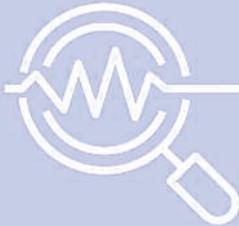
Diego Montalvo

Eduardo García Plaza

Carlos Romero-Camacho

Sofía Alía Rivero

Rubén Domínguez Íbar



REPSOL Trading como responsable del suministro y marketing de todos los crudos y productos producidos y/o consumidos por los negocios de Upstream y Downstream del grupo REPSOL realiza a diario operaciones en los mercados de físico y derivados. De esta forma, resulta de vital importancia disponer de una visión certera de la dirección de las cotizaciones para los distintos mercados a corto, medio y largo plazo a fin de optimizar el proceso de toma de decisiones.

En este contexto, los alumnos del CIC LAB han trabajado en la investigación y desarrollo de herramientas analíticas que, mediante la aplicación de técnicas de aprendizaje máquina ("*machine learning*"), permitan aportar valor a los procedimientos ya existentes.

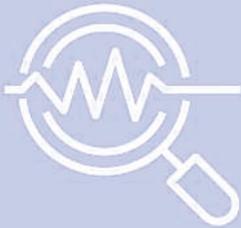
• IIOT EN ENTORNOS ATEX - REPSOL

PROYECTO IOT - REPSOL

VERANO 2020

Alumnos:

Beatriz Acosta Bejarano
Alejandra María Barceló Álvarez
Cristina de Lorenzo García
Juan-Lorenzo de Navascués Gómez



SEMANA 1 - DEFINICIÓN DE PROYECTO E INVESTIGACIÓN

En este proyecto se ha desarrollado un *Business Case* con el objetivo de estudiar la viabilidad tanto técnica como económica de instalar dispositivos IoT, que en este caso eran sensores de temperatura y vibraciones, además de toda la infraestructura de comunicaciones de dichos activos con los servidores en la nube.

Así pues, el objetivo de la primera semana fue definir líneas de actuación/requisitos para la incorporación de sensores IoT en una refinería de Repsol que permitan el mantenimiento predictivo de los equipos rotativos allí presentes a través de sensores de temperatura y vibraciones.

1.1. Matriz de Requisitos

Los requisitos que se deben cumplir son:

- **Certificación ATEX:** Las refinerías son consideradas lugar de "Atmósfera Explosiva". De acuerdo con la información de Repsol, se consideran Zona 1 o Zona 2 como requisito mínimo para la zona de trabajo de los dispositivos.
- **Calidad de los datos:** Especialmente en vibraciones, que se garantice un correcto espectro de armónicos de frecuencia con el equipo a monitorizar para evitar pérdida de datos. En este sector, es necesario tener en cuenta el **apantallamiento** de la señal que podría reducir la calidad de transmisión de los datos. Este factor está relacionado principalmente con el protocolo. Se debe analizar cómo se comunica el sensor con el *gateway* cuando hay obstáculos de por medio.
- **Temperatura de operación:** La temperatura máxima de operación debe estar en torno a los 70 - 80°C.
- **Certificación IP:** Sensores resistentes a la filtración de agua y polvo por estar situados en ambiente exterior. Se considera que el **mínimo nivel IP** que deben cumplir es el **IP55** (protección parcial contra el polvo (no afecta a su funcionamiento) y protección contra agua a baja presión). Sin embargo, **sería mejor** conseguir sensores con niveles **IP65** o superiores pues se garantiza la no entrada de polvo, y se podría aumentar su resistencia a los líquidos.



- **Duración de la batería:** Se necesitan sensores con larga vida útil y cuya batería sea fácilmente reemplazable.
- **Plug and Play:** Se busca facilidad en la instalación del sensor, así como en su intercambiabilidad. Es decir, que se puede cambiar de un equipo a otro y seguir operativo. Buscar soluciones genéricas para la refinería y no específicas para cada equipo.
- **Facilidad de instalación:** Para medir correctamente las vibraciones, el sensor debe montarse directamente sobre la superficie de la máquina. Esto puede realizarse mediante diversos tipos de montajes.
- **Alcance:** Se considera como requisito mínimo un alcance de 100-150 metros. Hay que analizar la posibilidad de incluir repetidores para ampliar el alcance según el sensor.
- **Protocolo Privado / No Privado:** Considerar las comunicaciones de los sensores y su capacidad de operación con IoT tradicional. Actualmente tienen servidor privado, sin embargo, se valora el pasarse a un servidor público para así, no depender de una empresa externa.
- **Costes:** Siempre tener perspectiva de costes, aunque se especificarán más adelante en el *Business Case*.
- **Comunicación UPSTREAM:** No se considera comunicación bidireccional, se ejecutan los algoritmos con los datos de los sensores y en base a ellos los ingenieros toman decisiones. No se envían señales de actuación.
- **Muestreo Flexible:** Aunque no precisa de monitorización continua (recoger datos cada segundo, minuto), el sistema debe ser capaz de cambiar su monitorización para momentos de arranque o rearme (en los que sí interesa recibir datos cada poco tiempo). Asimismo, también es importante esto para controlar y poder analizar la curva de desgaste de un equipo. Normalmente trabaja con medidas cada X horas.
- **Dos sensores:** Uno en el lado de la bomba, y otro en el lado del motor. Se utilizan monoaxiales (uniaxiales) y triaxiales.

1.2. Pirámide de prioridades

En vista a los requisitos y a la información conocida "a priori", se ha establecido el siguiente orden de prioridades (1-Alta; 2-Media; 3-Baja):

Se han considerado de alta prioridad los requisitos relacionados con el buen funcionamiento/normativa de la monitorización del sistema. Es decir, que se garantice que cumplen normativa ATEX, un buen espectro de frecuencias, temperatura de operación dentro de límites, certificación de resistencia para su instalación en ambientes exteriores.

Plug and Play se considera de prioridad alta teniendo en cuenta que la inversión busca ser algo que pueda modificarse a medida que pasa el tiempo y que no sea un sistema demasiado específico para cada equipo.

PIRÁMIDE DE PRIORIDADES

REQUISITOS	PRIORIDAD
Plug and Play	1
Calidad de datos / Armónico de frecuencias	1
ATEX (Z1/Z2 → GAS)	1
Tª Max / Tª Operación	1
Certificación IP	1
Influencia de las condiciones meteorológicas	1
Modificación del tiempo de muestreo / Flexibilidad	1
Facilidad de instalación	2
Coste del sensor	2
Coste de instalación	2
Ciberseguridad/Vulnerabilidad	2
Duración Batería	2
Protocolo/Servidor privado	3

1.3. Comparación protocolos

Los protocolos de comunicación IoT se clasifican en dos grandes grupos en función de su alcance:

- Protocolos de largo alcance (LPWAN):
 - **SigFox:** Red de comunicaciones LPWAN más extendida a nivel mundial, con un despliegue y cobertura casi global (casi 98% del territorio europeo y americano). Los fabricantes de IoT se han adaptado a su tecnología y facilitan la subida de datos a la nube de SigFox (accesible a través de cualquier conexión a Internet). También cuenta con un soporte en Microsoft Azure.
 - **LoRa:** Protocolo de transporte inalámbrico de datos que hoy en día se entiende como uno de los protocolos básicos para la implementación de IoT, ya que es la red LPWAN mejor preparada para una comunicación bidireccional en tiempo real con un dispositivo IoT.
- Protocolos de corto alcance:
 - **Wifi (2,4 GHz y 5 GHz):** Tecnología inalámbrica muy extendida para conectar dispositivos a Internet que también permite comunicar dispositivos entre sí cuando el acceso a Internet no es necesario.
 - **Bluetooth (BLE):** Permite interoperar pequeños dispositivos desarrollados para usar Bluetooth y destinados a mandar paquetes de datos reducidos.
 - **ZigBee:** Tecnología inalámbrica, muy robusta, con alta escalabilidad y capacidad de soportar un gran número de nodos.

Debido al reducido tamaño de los mensajes que van a enviar los sensores IoT, no se requieren redes de alta capacidad ni un envío inmediato de la información. Por ello, para conectar los dispositivos IoT a la nube, los protocolos de comunicación más adecuados son LoRa, entre las redes de largo alcance, y ZigBee o Bluetooth, entre las redes de corto alcance.



SEMANA 2 - SENSÓRICA IOT

El objetivo de la segunda semana fue definir una matriz de sensores candidatos empleando las características establecidas en la semana anterior. Para ello, se realizó una tabla con 21 posibles opciones y se fueron clasificando según las siguientes características:

- Marca.
- Tipo de sensor.
- Alcance.
- Características de vibración.
- Características de temperatura.
- Visualización de datos.
- Tiempo de muestreo.
- Protocolo de comunicación.
- Instalación.
- IP.
- Certificación Atex.
- Duración de la batería.
- Dimensiones.
- Peso.
- Coste.

2.1. Selección según características

Tras completar la matriz de candidatos, se dio un orden de magnitud a cada una de las características anteriormente mencionadas. De esta forma, se consigue dar una puntuación a cada sensor y determinar cuáles son las mejores y peores opciones teniendo en cuenta la pirámide de requisitos definida la primera semana.

2.2. Candidatos finales

Con la selección de los 6 mejores candidatos en base a lo comentado anteriormente, así como sus ventajas y desventajas, se procedió a analizar de forma más detallada y minuciosa cada uno de los sensores, así como su *gateway*. Se realizó una tabla donde las características iban determinadas según una clase. Se fue analizando qué cualidades tenía cada sensor respecto a las genéricas que habíamos marcado en cada clase.

Algunas de las clases para los sensores fueron:

- Adquisición: señal temporal, espectro, frecuencia de muestreo, filtro *antialiasing*, frecuencia máxima, nº de muestras, nº de líneas, cadencia mínima y modo de funcionamiento.
- Comunicaciones: tipo de comunicación, distancia a *smartbox*, certificación, API, comunicación abierta/cerrada, integración SW, exportación forma de onda, datos a nube vía sensor, datos a nube vía *smartbox* y función de autochequeo.
- Instalación: facilidad, escalabilidad y cableado.
- Especificación ambiental: temperatura de operación, IP, certificación y certificación de zona clasificada.
- Alimentación: tipo batería, monitorización, duración y sustitución.
- Arquitectura IoT.

Para el *gateway*, se determinaron otras clases como:

- Interfaz I/O Comunicaciones: nº entradas/salidas, ethernet, USB, serie.
- Interfaz Wireless: móvil, wifi, bluetooth, otros, antenas y conexión con sensor.
- Gestión del sensor: nº de sensores por *smartbox*, tipo de sensor soportado, posibilidad de otros sensores, configuración del sensor, SW, adquisición forma de onda y cálculo del espectro.
- Comunicaciones: tipo de comunicación, distancia al sensor, distancia al servidor, certificación RTU, software de monitorización, API, abierta/cerrada, SW, datos a nube vía sensor y datos a nube vía *gateway*.
- Instalación: facilidad, escalabilidad, portabilidad, posibilidad maleta.
- Especificación Medioambiental: temperatura de operación, IP, certificación y certificación de zona clasificada.

SEMANA 3 - BUSINESS CASE

3.1. Business Case

Tras la comparativa de los sensores candidatos se realizó el *Business Case* de cada uno de ellos para un proyecto de 5 años. Las condiciones de partida supuestas son las siguientes:

- La planta está formada por 30 unidades de crudo.
- El MTBF (tiempo entre cada fallo) de los equipos es de 1600 días.
- Se necesitan 2 sensores (bomba y motor) por equipo rotativo monitorizado.
- No se tiene que monitorizar el 100% 24/7.
- 1600€ por antena instalada.
- 1300 € de ahorro por cada intervención (274 intervenciones anuales evitadas) → 356k€.
- 25€/h de mano de obra en operaciones de mantenimiento.

Con los datos relacionados de la planta y los costes de los sensores y *gateways* se llevaron a cabo las siguientes estimaciones:

- 1200 equipos rotativos a monitorizar en la refinería (40 x unidad de crudo según los planos).
- Tiempo de recambio de baterías → 1h/batería.
- Tiempo de mantenimiento por recambio de sensor → 2h/sensor averiado.
- Tiempo mantenimiento general → 1h/sensor.
- Tasa de sensores averiados anualmente → 10%.
- 1500 sensores (750 equipos monitorizados 24/7) → 63,3% del total de equipos.
- Tasa de descuento para el VAN → 10%.



3.1. Observaciones *Business Case*:

El *Business Case* planteado a continuación refleja la opinión y conclusiones del equipo de estudiantes del CIC LAB. En ningún caso recoge valoraciones ni preferencias que REPSOL haga suyas.

Según pudo observar el equipo, los resultados y rentabilidad obtenidos varían mucho de un sensor a otro debido principalmente a la gran diferencia que presentan en los costes unitarios. En algunos casos, la inversión no se recupera a lo largo de la vida del proyecto siendo descartado ese candidato automáticamente. Otros presentan rentabilidades muy bajas pero que precisan de conocer la tasa de descuento para poder decidir si la inversión puede llevarse a cabo. Finalmente, se optó por un candidato con una rentabilidad elevada (TIR=35%), el óptimo dentro de todos los sensores estudiados.

Es preciso remarcar que estos *Business Case* presentan algunas estimaciones y por ello su resultado podría variar con los datos reales. Además, cabe mencionar que los sensores deberían ser analizados en la planta con el objetivo de comprobar si la calidad de los datos que almacenan es suficientemente buena.

SEMANA 4 - ARQUITECTURA IOT

En esta sección, de nuevo, aparecen comparativas entre algunas soluciones comerciales que han sido realizadas por los alumnos colaboradores. Como tales, representan sus conclusiones obtenidas en apenas una semana de (buen) trabajo. Por lo tanto, y por la naturaleza meramente informativa de las mismas, no deben considerarse validadas por REPSOL ni consistentes con la opinión de REPSOL sobre las distintas soluciones para la arquitectura de proyectos IoT disponibles en el mercado.

4.1. Formación Arquitectura IoT

Capas de la arquitectura IoT:

- Capa Hardware: sensores, actuadores, microcontrolador, etc.
- Capa sistemas de información.

Se utiliza una red de comunicaciones para enlazar ambas capas. Tipos de red de comunicaciones:

- **Monolíticas**, sensores se comunican directamente con el sistema de información (p.ej. 3G/4G o SigFox).
- **Jerárquica**: Existen diferentes segmentos y cada segmento puede usar protocolo de comunicaciones distinto.

Factores a tener en cuenta a la hora de elegir la red de comunicaciones:

- Consumo.
- Alcance.
- Coste. Principalmente depende de la complejidad de la tecnología y si es o no una tecnología muy utilizada.
- Tasa de transmisión, velocidad a la que se pueden transmitir datos // Periodo de muestreo. Para este caso no se requiere alta tasa de transmisión al no trabajar con archivos multimedia.
- Gateway (Agregación).
- No es necesario a tiempo real la transmisión de datos.
- Mensajes bidireccionales.

Opciones de Cloud Service:

COMPARATIVA ALTERNATIVAS CLOUD

	Pública	Privada	Híbrida
Características	Comparte el mismo hardware, almacenamiento y dispositivos de red con otras organizaciones en la nube	Servicios e infraestructura siempre se mantienen en una red privada y el hardware y el software se dedican exclusivamente a su organización	Los datos y aplicaciones pueden moverse entre nubes privadas y públicas para una mayor flexibilidad
Seguridad	Sí, la debe garantizar el proveedor del servicio, pero todos los datos (confidenciales o no) están en la nube pública	Mejorada, no se comparten los recursos con terceros	Sí, se puede utilizar nube privada para datos confidenciales
Control	Menor	-	Mayor control
Mantenimiento	No, lo asegura el proveedor	No	No
Escalabilidad	Casi ilimitada	Sí	Sí
Flexibilidad	Baja	Sí, personalizable	Sí
Coste	Bajo, sólo se paga el servicio	Mayor	-
Ejemplos	Microsoft Azure / Google Cloud / AWS	NetApp/Cisco...	Microsoft AzureStack/ NetApp+AWS /Google Cloud+ Cisco

Opciones de protocolo de comunicación entre el sensor y el *gateway*:

- **NarrowBand IoT (NBLoT).**
- **Sigfox.**
- **Lora.**

Opciones de arquitectura IoT para la refinería:

- BLE o ZigBee de sensores a *gateway* y de estos a la estructura de información o cloud (Microsoft Azure) utilizar red corporativa (Ethernet o Wifi).
- NBLoT / Sigfox / LoRa para comunicar sensores con *gateways* y de estos a la estructura de información o Cloud (Azure) utilizar red corporativa (Ethernet o Wifi).

4.2. Gestión de red

La gestión de red es muy importante en este tipo de infraestructuras IoT. Quizás el protocolo más utilizado para gestionar redes de comunicaciones es **SNMP**. Por otra parte, hay muchas herramientas y plataformas para gestión de redes de comunicaciones, por ejemplo:

- **Cacti** (basado en RRDTool y net-snmp).
- **Icinga 2.0** (fork de Nagios).
- **OpenNMS.**
- **PandoraFMS.**
- **Zabbix.**



En cuanto a la infraestructura de gestión de red se distinguen el front-end o interfaz de usuario y el back-end o servidor y flujo de información que circula por el cloud, front-end y back-end. Este flujo de información es el que será controlado por las APIs.

En este apartado del trabajo de investigación, se determinó el alcance del front-end y back-end y los requisitos que se consideran necesarios para una aplicación de este tipo. Sin embargo, no se ha llegado a profundizar en las herramientas y protocolos de gestión de red anteriormente mencionados y, por lo tanto, sería una buena rama por la que continuar investigando para decidir qué protocolo es el óptimo.

• Gestión de las APIs

Se encargará de conectar las peticiones del front-end y el cloud computing con la base de datos. Así como también se encargarán de escribir y modificar cuando sea necesario. Es el nexo de los flujos de información entre las diferentes partes de la infraestructura.

API Management:(APIM) es una manera de crear puertas de enlace de API coherentes y modernas para servicios de back-end existentes. Ayuda a las organizaciones a publicar API para desarrolladores externos, asociados e internos para liberar el potencial de sus datos y servicios.

4.3. Arquitectura de comunicación IoT

Para el diseño de la arquitectura es necesario tener en cuenta el protocolo a nivel aplicación con el que trabaja el Gateway y el Cloud. Se puede dar el caso de que no utilicen el mismo protocolo, requiriendo implementar un conversor en la arquitectura. Esto ocurre en el caso de *gateways* que trabajan en Modbus y que se desean conectar a un sistema Cloud de MS Azure, el cual trabaja con el protocolo MQTT. Dos de los sensores analizados en este proyecto requieren estos convertidores para ser compatibles con MS Azure tal y como se ha planteado en el ejemplo de arquitectura anterior.

Protocolos IoT a nivel Aplicación:

El **nivel de aplicación** o **capa de aplicación** es el séptimo nivel del modelo OSI. Ofrece a las aplicaciones (de usuario o no) la posibilidad de acceder a los servicios de las demás capas y define los protocolos que utilizan las aplicaciones para intercambiar datos, como correo electrónico, gestores de bases de datos y protocolos de transferencia de archivos.

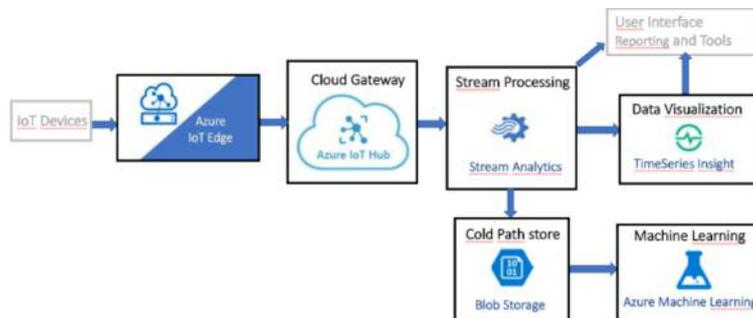
Dentro de este nivel de la capa OSI encontramos, principalmente, 3 protocolos de comunicación más orientados a la industria:

- **MQTT:** seguridad, sencillez y localizaciones remotas.
- **AMQP:** interoperabilidad, fiabilidad y escenarios más amplios y complejos.
- **CoAP:** protocolo diseñado para objetos simples o con limitaciones a nivel de la capa de aplicación y posee una arquitectura basada en servicios web en lugar de una orientación a la mensajería. Está pensado para sensores de baja potencia y para aplicaciones destinadas al intercambio *machine to machine* (M2M).

4.4. Arquitectura IoT – Microsoft Azure

Considerando los requisitos y limitaciones del proyecto, se presenta el siguiente ejercicio de implementación de una posible arquitectura IoT. El ejercicio está basado en la arquitectura de MS Azure, que en su versión más básica puede considerarse la siguiente:

ARQUITECTURA IOT PROPUESTA



Los componentes de esta arquitectura son los siguientes:

- **IoT devices:** Son los dispositivos IoT, en nuestro caso, los sensores de vibración y temperatura para equipos rotativos.
- **IoT Edge devices:** dispositivos perimetrales que realizan algún tipo de procesamiento de datos en el propio dispositivo o en una puerta de enlace de campo.
- **Cloud Gateway (IoT Hub):** Es la puerta de enlace en la nube que permite que los dispositivos IoT se conecten de forma segura a la nube y envíen datos. Microsoft MS Azure recomienda el servicio IoT Hub, es un servicio hospedado en la nube que comunica los dispositivos con los servicios back-end, proporciona conectividad segura, ingesta de eventos, comunicación bidireccional y administración de dispositivos.
- **Stream processing (Stream Analytics):** Servicio de análisis en tiempo real totalmente administrado, diseñado para ayudar a analizar y procesar flujos de datos rápidos que se pueden usar para obtener información, crear informes o desencadenar alertas y acciones. Azure Stream Analytics es un motor de procesamiento de eventos complejo y de análisis en tiempo real que está diseñado para analizar y procesar grandes volúmenes de datos de streaming rápido para varios orígenes de manera simultánea. Los patrones y las relaciones se pueden identificar en la información extraída de varios orígenes de entrada, como dispositivos, sensores, secuencias de clics, fuentes de medios sociales y aplicaciones.
- **Azure Machine Learning:** Permite ejecutar algoritmos de predicción en datos de telemetría históricos, por ejemplo, para mantenimiento predictivo. Proporciona los SDK para Python y R y el diseñador de tipo "arrastrar y colocar" para crear e implementar modelos de aprendizaje automático. Studio (clásico) solo ofrece una experiencia independiente de arrastrar y colocar.
- **Azure Blob Storage:** Ofrece el almacenamiento en rutas de acceso inactivas. Base de datos para archivar datos de forma indefinida a bajo costo y es fácilmente accesible para el procesamiento por lotes. Blob Storage está optimizado para el almacenamiento de cantidades masivas de datos no estructurados.
- **TimeSeries Insight (Data Visualization):** Es una oferta de plataforma como servicio (PaaS) de un extremo a otro. Se puede usar para recopilar, procesar, almacenar, analizar y consultar los datos en la escala de Internet de las cosas (IoT), datos que están muy contextualizados y optimizados para las series temporales.

Con todos estos servicios de MS Azure, básicos para el mantenimiento predictivo que se quiere llevar a cabo en la refinería, se establece la arquitectura IoT del proyecto.

Todas las conclusiones y opiniones presentes en este documento, fueron realizadas específicamente por el grupo de alumnos participantes del CIC LAB, y no constituyen ni comprometen opiniones de Repsol.



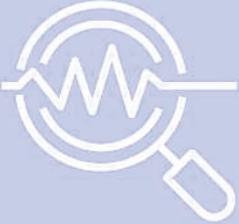
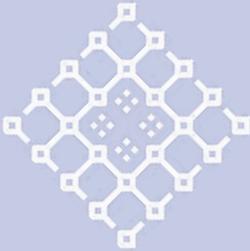
• ANALÍTICA AVANZADA EN LA RED DE DISTRIBUCIÓN - ENDESA

**ANÁLISIS DE ACTIVOS ELÉCTRICOS
EN LA SMART CITY DE MÁLAGA**

JUNIO/JULIO 2020

Equipo de trabajo:
*Laura Blas Álvarez,
 Teresa Gella Zubizarreta,
 Juan Luis Jarillo Gómez,
 Pablo Mendoza Caballero,
 Javier Ochoa de Aspuru Aguilar*

Resumen realizado por
Andrés García

I. INTRODUCCIÓN

En la actualidad, nos encontramos ante un proceso de globalización a todos los niveles. En particular, la **digitalización de la red** es un proceso de cambio a la hora de operar que facilita la **utilización de las nuevas tecnologías** y mejora la **provisión de energía** para la transformación tanto industrial como doméstica.

El sector eléctrico tiene el objetivo de monitorizar el consumo en tiempo real. En España ya está prácticamente hecho gracias a los contadores inteligentes, pero además surge la necesidad de poder **operar** la red de distribución de **manera más inmediata**. Esta necesidad surge del **aumento de la generación distribuida** que realiza pequeños aportes de energía a la red. **Sin embargo**, estas pequeñas generaciones **no disponen de un control de frecuencia**, lo que es fundamental para mantener la estabilidad de la red.

Las *Smart Grids* son cada vez más necesarias y con ello se pretende poder operar en la red de distribución de manera local aquellos activos que presenten comportamientos similares.

Para realizar un estudio de los centros de transformación de la ciudad de Málaga se **utilizó la técnica de las componentes principales** (PCA) para poder encontrar **similitudes entre transformadores** y estudiar su funcionamiento. Con la información obtenida se pretende evaluar tanto el funcionamiento de los CT durante los meses de confinamiento como durante los meses anteriores y posteriores.

2. PREPROCESAMIENTO DE DATOS

2.1. Estudio primario de las variables – detección de valores atípicos

Se realizaron **cinco diagramas de Box-Plot** en los que se recogen los valores registrados de los parámetros de **tensión, intensidad, potencia activa, potencia reactiva inductiva y, potencia reactiva capacitiva** en la línea 1 en cada una de las subestaciones.

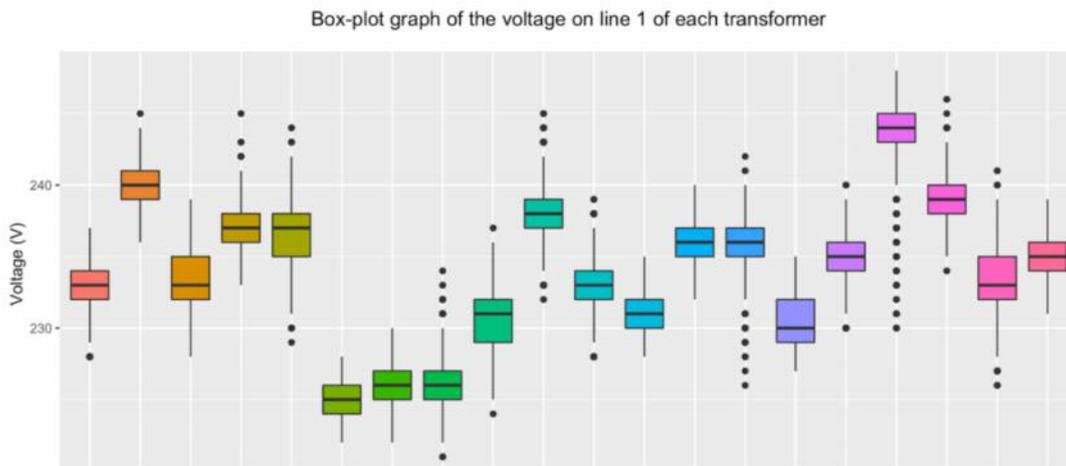


Figura 1: Ejemplo de gráfico Boxplot de la tensión de la línea 1 en cada CT

El rango de variación y número de **outliers** de tensiones es **reducido**. Esto se debe a que, al ser **parámetros nominales de los activos**, la variación de sus valores está sujeta a **menos cambios durante la operación**. No ocurre así con las gráficas de intensidad y potencia activa. Se deben a aumentos puntuales y dependen fuertemente de sobrecargas.

El primer registro de **datos atípicos** se encuentra en el estudio de las **potencias activas**, pues en **muchos casos alcanzan valores negativos**. Esto puede deberse a que el transformador está exportando energía, debido a **la instalación de placas solares o algún otro elemento que retorne energía** o por el contrario a un **error en la medida** o en el procesamiento de los datos. Se optó por eliminar estos registros del conjunto de datos por ser un porcentaje reducido del *dataset* inicial.

La siguiente incidencia encontrada en el estudio preliminar de las variables eléctricas es la aparición de valores de **potencia reactiva capacitiva positivos**. Esto puede deberse, como en el caso anterior, a una **exportación de energía desde el consumo, a una mala instalación del supervisor o a un procesado incorrecto de los datos**. Se opta también por su eliminación.

Además, el coseno de phi no se ha tenido en cuenta en este informe, ya que la información que se puede obtener de valores binarios es irrelevante en este caso.

2.2. Calidad del *dataset*

El archivo original contiene un total de 167.548 observaciones. En primer lugar, se eliminan aquellas observaciones en las que alguno de los **parámetros no tiene valor (N/A)**, al ser únicamente ocho los registros.

En segundo lugar, se abordan los registros diferentes de **horarios duplicados**. Debido a la falta de información acerca del motivo por el cual se cuenta con valores distintos, se opta de manera provisional por eliminar el segundo registro.



En tercer lugar, se ha identificado un total de 4.913 medidas de tiempo que **no presentan registro de medida**. Se ha podido comprobar cómo algunas de estas ausencias se corresponden con periodos de reparación del equipo, aunque otras quedan injustificadas.

Se concluye por tanto que el conjunto de datos es válido para llevar a cabo el estudio y que se cuenta con observaciones suficientes (127.255 registros) para poder extraer información relevante sobre la operación de los distintos centros de transformación perteneciente a la Smart City.

3. ESTUDIO DE CORRELACIÓN ENTRE VARIABLES

A continuación, se trazaron las correlaciones entre variables de cada línea de tensión, corriente, potencia activa y potencia reactiva (inductiva y capacitiva) en tres subestaciones ejemplo de comportamiento dispar.

Las medidas de las subestaciones tienen de manera relevante y general a los tres casos **una fuerte correlación lineal entre potencia activa y corriente**. En el gráfico que relaciona ambas variables siempre **se forman de dos a cuatro grupos de datos de pendiente muy similar** y todos con forma lineal. También es destacable, aunque más levemente **la formación de clusters entre potencia activa y reactiva inductiva**, o entre **tensión y potencia activa**, consecuencia del mismo fenómeno que son esos grupos separados visiblemente ya entre activa e intensidad.

4. ANÁLISIS DE CENTROS DE TRANSFORMACIÓN MODELO

Se procede al análisis de un subconjunto de centros de transformación modelo. **Los CT elegidos** para este análisis **son el C4** debido a que se aprecian **cambios en su comportamiento a lo largo de las horas del día**. El centro **C5** debido a que se aprecian **cambios de funcionamiento entre los días de fin de semana y los días entre semana**. Y por último el **C6** debido a **cambios de comportamiento según el mes del año**.

4.1. Análisis de componentes principales

Esta herramienta permite representar el conjunto de observaciones en un plano bidimensional y facilitar la agrupación de centros siguiendo criterios de semejanza.

El primer paso antes de proceder al análisis de resultados es **comprobar la validez del análisis**. El porcentaje es del **72,5% para dos componentes**, siendo aceptar su estudio para hacerlo extrapolable a todos los datos. Es interesante destacar que con sólo 4 componentes se alcanza el 95,5 % de la varianza explicada, y que por tanto se trata de una buena reducción de la información.

4.1.1. Las primeras componentes principales (PC1 y PC2)

Cada uno de los **puntos representados** se corresponde con **una medida horaria tomada en un transformador**. La representación en el plano recoge información de los valores que toma **cada observación para las dos componentes**, que son un índice en el que se recogen los comportamientos más destacables dentro de cada transformador.

Primera componente

En la **PC1 destacan fuertemente la intensidad, la potencia activa y la potencia reactiva tanto inductiva como capacitiva**. Esto es debido a que, **al aumentar la carga** asociada a un CT, **aumenta la intensidad** circulante por las líneas y **aumentan las pérdidas**, produciéndose así una **disminución de la tensión**.

Por último, **los valores de las tres líneas guardan una relación similar**, ya que en el régimen normal la red trifásica está equilibrada.

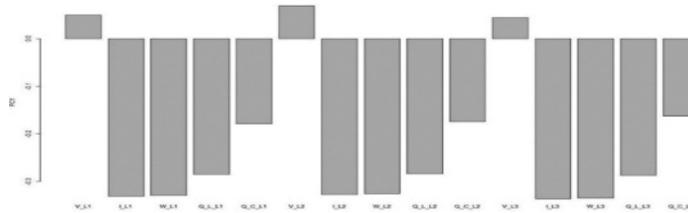


Figura 2. Primera componente principal del Análisis PCA

Segunda componente

Esta componente modela de forma más clara la **relación inversamente proporcional que existe entre la tensión y la potencia reactiva capacitiva**.

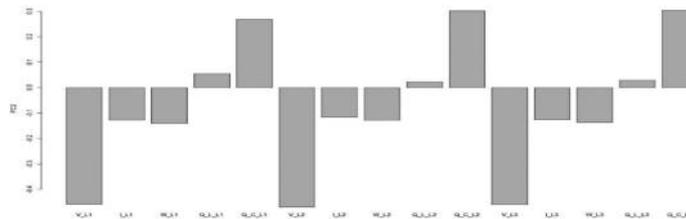


Figura 3. Segunda componente principal del análisis PCA

4.1.2. Distribución de los autovectores

En el siguiente gráfico se representan las observaciones coloreadas según el CT al que pertenecen. Como vemos, **cuanto mayor sea el peso de una variable en la componente principal, más cerca se encontrará la variable al eje de esa componente principal**.

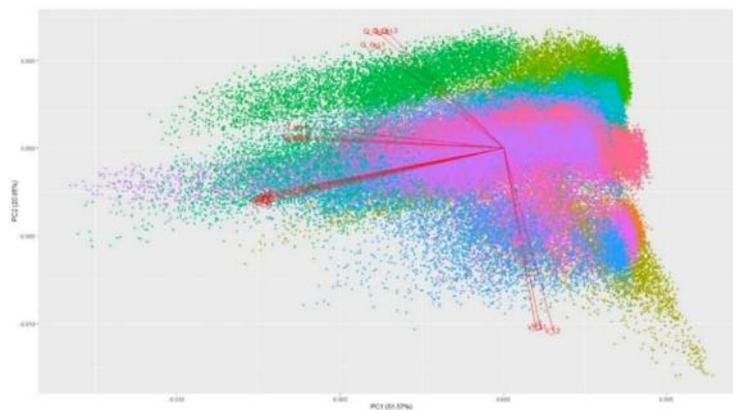


Figura 4. Plot de todos los datos de cada CT

4.2. Centros de transformación modelo

4.2.1. Análisis del centro C4

Este centro ha sido elegido porque presenta un comportamiento **diferente** para las **distintas horas del día**.

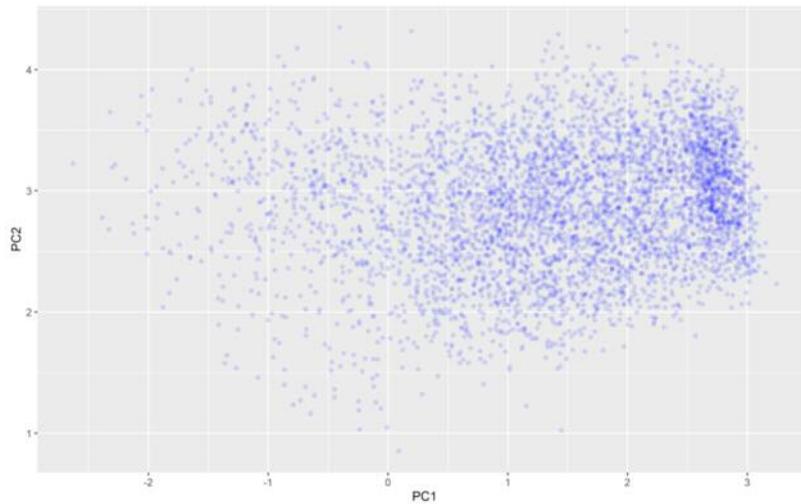


Figura 5. Plot de los datos del CT C4

La nube de puntos es más densa en su parte derecha en torno a valores estrechos de PC1, con mayor variabilidad en PC2. Esto **indica que el transformador opera a una carga similar, pero con variaciones de tensión y de potencia reactiva capacitiva.**

Por tanto, **se trata de un transformador que varía su punto de operación, aunque suele operar con una carga determinada**, dándose la **mayor dispersión en la tensión.**

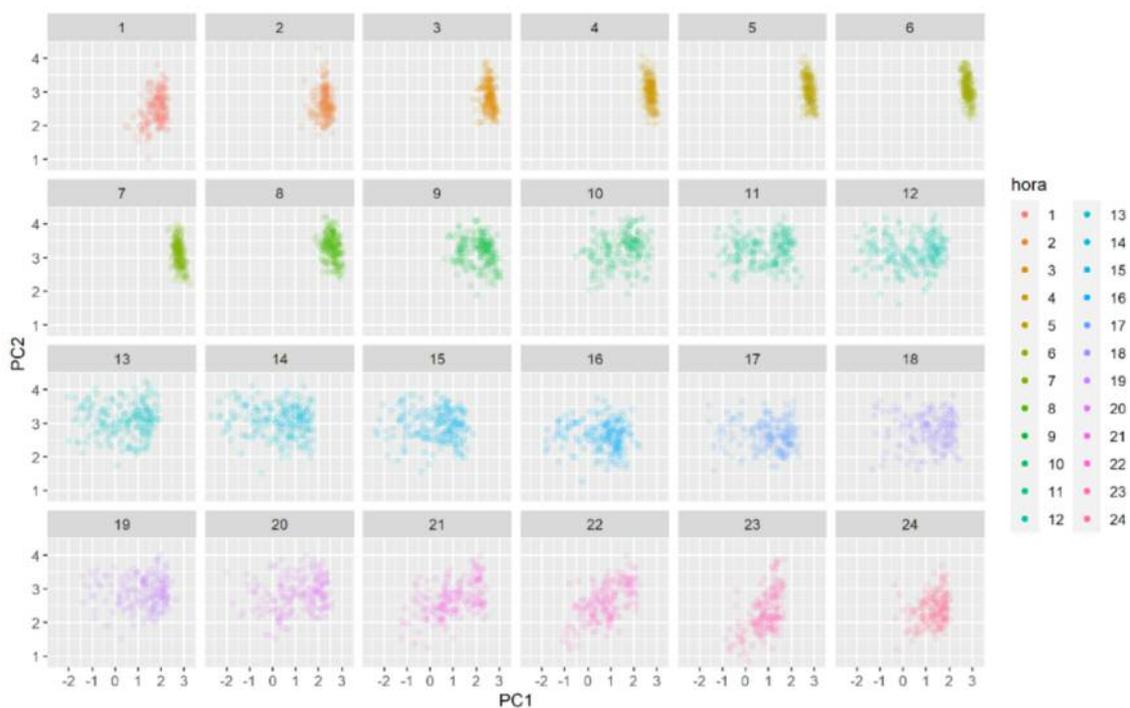


Figura 6. Plot de los datos del C4 según la hora del día

Este CT alimenta pues en su mayoría una zona de oficinas donde el consumo durante la noche es pequeño y poco variable. Durante el día, se homogeniza la nube de puntos y aumenta en variabilidad de carga.

4.2.2. Análisis del centro C5

El CT destaca por el **cambio en su comportamiento en función de si es día laborable** o fin de semana. Estudiando su comportamiento, podría ser una zona residencial con comercios u oficinas pues hay **variabilidad en los datos entre las 20 a las 24h** (horas de cena y de dormir), comportamiento explicable si hay casas además de oficinas o comercios, provocando variación entre días laborables y fines de semana.

3.2.3. Análisis del centro C6

Se ha elegido el CT C6 para analizar su comportamiento en **diferentes meses del año**.

Esta nube de puntos tiene **forma de boomerang**, con **tres núcleos de mayor concentración de puntos**, uno explicado por la reactiva capacitiva, otro por la reactiva inductiva y otro por la potencia activa.

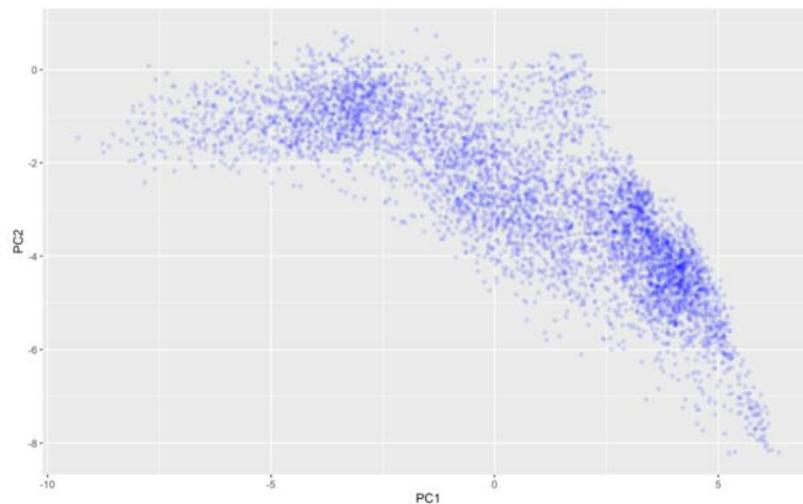


Figura 7. Plot de todos los datos del CT C6

5. ANÁLISIS GENERAL DE LA SMART CITY

5.1. División de los transformadores en grupos representativos

Para llevar a cabo las agrupaciones, se ha valorado **la posición relativa al origen, variabilidad similar en ambas componentes principales y orientación de la nube**.



Grupo 1: C2, C3 y C7

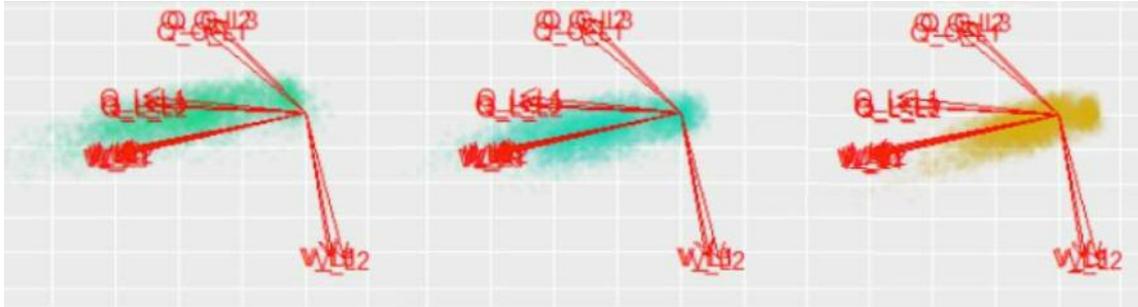


Figura 8. Plot de los centros C2, C3 y C7

Esta similitud se debe a que los tres dan soporte a zonas con unas características muy similares: **son áreas residenciales urbanas de tipo apartamento.**

Grupo 2: C8, C4 y C9

Aquí la agrupación es algo diferente a los esperado ya que estos **tres centros alimentan a zonas geográficas diferentes.** Sin embargo, los **niveles de carga de la red son muy similares** (eje x de la gráfica) así como los niveles de tensión también son parecidos. Además, el rango de cargas entre CTs es muy similar entre ellos (amplitud en el eje x).

Grupo 3: C10, C11 y C12

Los tres CT se encuentran en la zona centro/sur de Málaga, en zonas residenciales.

Grupo 4: C13 y C14

Los datos aparecen menos compactos, pero comparten posición del origen de coordenadas, forma y tamaño de la distribución. Ambos CT se sitúan en zonas cercanas, lo deja intuir un funcionamiento similar frente a la demanda. El hecho de que no varíe mucho estacionalmente **sugiere que son barrios donde hay poca presencia de turistas.**

Grupo 5: C5 y C15

Se observan transformadores colocados en zonas muy distintas pero que ambos abastecen bloques de pisos con comportamientos parecidos en primera estancia.

Grupo 6: C16 y C17

Respecto a las características para realizar la agrupación, ambos CT presentan similitud en forma y tamaño de los datos y en la posición del origen de coordenadas.

Grupo 7: C18, C6, C19, C20 y C1

Este último grupo recoge todos los CT que no se pueden clasificar en ningún grupo. Se comportan **distinto a otros grupos y entre sí.** Es por ello el no ser incluidos en ninguna de las agrupaciones anteriores. Además, sus posiciones geográficas son muy dispersas.

5.2. Efecto del fin de semana sobre la carga de los transformadores

Se observan dos agrupaciones: **la primera** es aquella en la que los **días festivos se sitúan en la parte derecha de la distribución, sin generar una cola ni superponerse** con los datos de días laborables. Los transformadores afectados pertenecen principalmente a la zona centro de Málaga y a zonas industriales periféricas. **Por otro lado**, el resto de CTs **siguen un patrón distinto** donde datos de días festivos superponen los días laborables.

5.3. Efecto del mes sobre la carga de los transformadores

En primer lugar, se aprecian **los efectos del Covid-19 sobre la demanda eléctrica de los meses de abril y mayo de 2020**. En prácticamente todas las subestaciones se aprecia una disminución considerable de la carga. Los transformadores más afectados por la pandemia son en primer lugar el centro C6. No solo se ha reducido su carga, sino que también se han desestabilizado otros parámetros de la red, como refleja el análisis de componentes principales.

Consideramos que este análisis de qué transformadores se vieron más afectados por el confinamiento puede ser de gran utilidad para predecir el comportamiento de la red si durante el invierno el gobierno vuelve a imponer un confinamiento sobre la ciudad de Málaga.

5.4. Efecto de la hora del día sobre la carga de los transformadores

Los **únicos centros** en los que se aprecian **pocos cambios con las horas** son el C9 y el C3, pues el núcleo de datos se mantiene constante durante todo el día sin experimentar grandes variaciones. Se puede observar que los dos transformadores se encuentran en la **zona exterior de Málaga** y son los que **más lejos del centro se encuentran** de los 20 CTs estudiados, y se podría suponer que se trata de una zona industrial, pero se sabe que esas dos zonas son residenciales.

6. DESEQUILIBRIOS DE LA RED

Una de las características que permiten diferenciar **comportamientos atípicos** en el funcionamiento de la red son los **desequilibrios producidos entre cada una de las fases**. Para llevar a cabo este estudio, se usa un análisis PCA introduciendo las **diferencias entre parámetros equivalentes de cada una de las tres fases**. Una línea perfectamente equilibrada mostrará pues valores nulos para los parámetros estudiados en esta sección.

6.1. Análisis de las componentes principales

El inconveniente frente al estudio anterior es el **reducido porcentaje de la varianza que se explica con las primeras dos componentes principales**, siendo este únicamente del 45,1%. Los resultados que se obtienen pueden no ser representativos del conjunto, pero se ha podido extraer información relevante para el estudio.

6.1.1. Las primeras componentes principales (PC1 y PC2)

La PC1 recoge los desequilibrios producidos por **un aumento de la tensión en la primera fase** sobre las otras dos. Los cambios relevantes que produce tienen lugar en la corriente y la potencia activa, produciéndose una reducción significativa de ambos parámetros en la tercera fase con respecto a la primera y segunda.

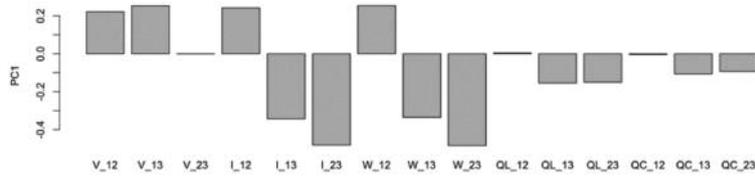


Figura 9. Ponderación primera componente principal

En cuanto a la PC2, se aprecia la relación inversamente proporcional que tiene la carga de la fase uno respecto a las otras dos, con el aumento de la tensión por esta línea.

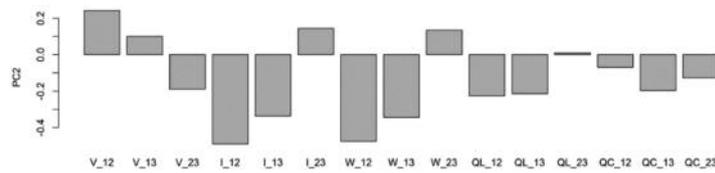


Figura 10: Ponderación segunda componente principal

6.1.2. Distribución de los autovectores

En este caso, las direcciones de los vectores no quedan agrupadas por parámetros de manera tan clara como en el estudio anterior, lo cual dificulta en algunos casos la explicación física de las distribuciones.

Es interesante comprobar cómo los autovectores de desequilibrios en la intensidad y la potencia activa se agrupan por fases y no por parámetros. Es decir, el desequilibrio de la fase uno sobre la dos tanto en corriente como en potencia activa se produce en la misma dirección, por lo que su variabilidad se da siempre en la misma dirección.

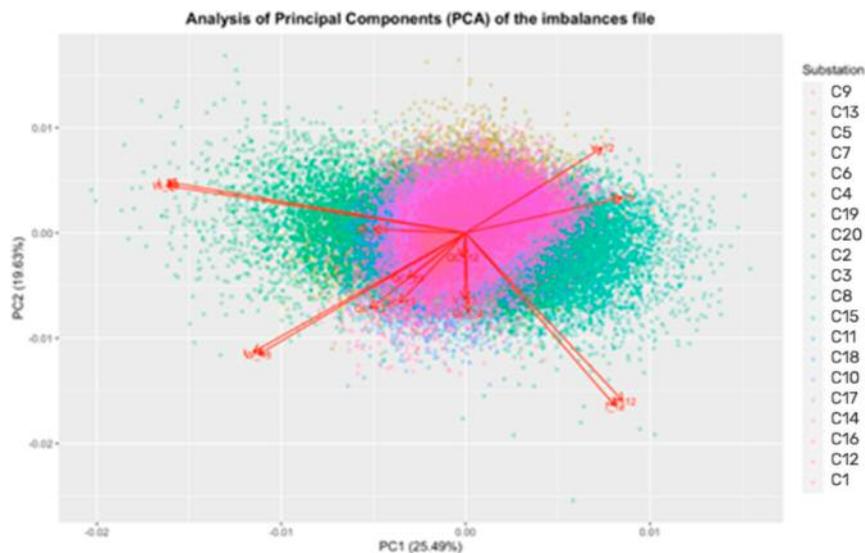


Figura 11. Plot diferencias entre líneas

6.2. Estudio de desequilibrios en CT modelo

Se estudian primero unos centros de transformación modelo, para después generalizar las conclusiones englobando todo el conjunto de la Smart City.

Los escogidos son el **C1** por presentar **desequilibrios prácticamente inexistentes**; el centro **C2**, que cuenta con el **mayor número de incidencias registradas**, y el **C3** que **no sufrió ninguna incidencia** durante la operación en el periodo de tiempo estudiado.

6.2.1. Análisis del centro C1

El CT C1 presenta la menor dispersión de entre los veinte centros estudiados en este informe. Se puede decir que ofrece un comportamiento ideal en cuanto a desequilibrios se refiere.

Además, en los días de diarios, la varianza de los puntos es mayor en el eje x, es decir, en la componente 1, causado por mayores variaciones en la carga, seguramente debido a la actividad industrial y de oficinas en la zona.

6.2.1. Análisis del centro C2

La distribución de la nube es un ejemplo esclarecedor de cómo se suelen distribuir las de aquellos CT con mayor número de incidencias. Tiene que ver con la localización de la nube en el plano de las componentes principales: la mayor parte de los centros con elevado número de fallos presentan **distribuciones muy centradas en los valores negativos de PC1**. Esto supone un **elevado número de desequilibrios en las cargas conectadas a la segunda y tercera fase de la red**, lo que puede ser el causante del elevado número de fallos. Se comprobó que la distribución es uniforme a lo largo de todos los meses, con excepción de enero de 2020, en el que tienen lugar la mayoría de los valores raros o *outliers*.

6.2.2. Análisis del centro C3

De manera contraria al anterior, **la nube de puntos se encuentra en valores positivos de la PC1**. Esta distribución es compartida por otros centros con incidencias nulas.

6.3. Estudio de desequilibrios en el conjunto de CTs de la Smart City

El primer grupo está formado por CTs con **desequilibrios** fundamentalmente **de tensión**. Aquí se encuentran el C5, C7, C20, C3, C8, C10, C16, C12. Se están produciendo **pérdidas tanto de potencia activa como de reactiva** que pueden ser evitadas con un **mejor control de la red**. Además, tiene la peculiaridad de estar relativamente equilibrados en cuanto a demanda se refiere.

El segundo grupo lo forman aquellos centros con **desequilibrios en la potencia**. Aquí se encuentran los grupos C6, C19, C2. Existe una diferencia significativa en cuanto a la potencia demandada por la red. **En núcleos residenciales** cada una de las líneas de la red se conecta a un **área poblacional que supuestamente tendrá la misma o muy similar demanda**. Sería interesante la reevaluación de la asignación de estos para intentar obtener un mayor equilibrio en la demanda.



El tercer grupo son aquellos centros con **desequilibrios significativos tanto de tensión como de potencia**. En este están los centros C9, C7, C4, C15, C17, C14 y C12.

Por último, mencionar aquellos con **mayor grado de equilibrio**, cuya nube de puntos se centra en el origen de los autovectores. Estos son los centros C1, C18, C13 y C11.

7. REGISTRO DE FALLOS

Las incidencias recogidas en el informe atienden a **causas muy variadas**, que recogen desde fallos debidos a **inclemencias meteorológicas** (temporales o inundaciones), **sobrecargas** (muy comunes), que mayoritariamente dependen del cliente, **degradación de los materiales** o **paradas** debido a mantenimiento con paradas programadas y puestas en explotación.

Los CTs que cuentan con menor cantidad de incidencias se deben fundamentalmente a la degradación del material y a normalizar maniobras, disparo de cabecera, sobrecarga y trabajos programados.

Número de incidencias por cada centro de transformación perteneciente a la Smart city										
Centro de Transformación	C2	C11	C6	C17	C9	C19	C1	C7	C12	C4
Número de Incidencias	17	10	7	7	6	6	6	5	5	4
Centro de Transformación	C10	C5	C8	C13	C15	C18	C16	C20	C3	C14
Número de Incidencias	4	3	3	1	1	1	1	0	0	0

Tabla 1. Tabla de incidencias

8. CONCLUSIONES

En primer lugar, conviene preguntarse por qué de un elevado número de datos atípicos se desconoce la causa. De ser algún tipo de fallo técnico o error en el tratamiento de los datos, se puede respaldar la decisión de haberlos eliminado; y si por el contrario se demostrase que tienen su origen en razones técnicas, como la instalación de paneles fotovoltaicos o dispositivos generadores similares, esta información podría ser el punto de partida de un análisis adicional.

El empleo de técnicas de **análisis de componentes principales** se ha escogido por resultar un **método sencillo e intuitivo** a la hora de identificar comportamientos similares en el funcionamiento de los transformadores. Al ser tan elevado el número de parámetros y al estar triplicados, resultó convincente emplearse antes del estudio.

En el caso del análisis de **parámetros eléctricos**, la **varianza explicada con las dos primeras componentes es suficiente** para considerar las conclusiones significativas y extrapolables al resto del conjunto. **No ocurre así** en otros casos, en los que es necesario emplear más de cinco componentes para explicar un porcentaje de varianza similar. Este hecho se traduce en que las conclusiones obtenidas de ese análisis son menos fiables en lo referente a generalizaciones.

Los **desequilibrios producidos** en las redes de los centros de transformación **guardan una estrecha relación en muchos casos con el número de incidentes registrados**. Se producen dos tipos de desequilibrios de manera más frecuente, unos por **desequilibrios de las cargas** conectadas a cada una de las fases, y otros por **desequilibrio entre las tensiones de las líneas**. Se ha observado como el primer grupo de desfases conlleva un elevado número de incidencias en los centros de transformación, mientras que los de tensión no parecen relevantes en este aspecto. Se concluye por tanto que se debe prestar especial atención a las cargas conectadas y al equilibrio de estas entre las líneas para reducir el número de incidencias en la operación de la Smart City.

A lo largo del análisis pudimos observar el efecto del confinamiento sobre los diferentes centros de transformación. Los más afectados fueron C6, C10, C18, C5, C20, C11, C19, C4 y C17. Estimamos que, en caso de un nuevo confinamiento, los centros que se vieron más afectados volverán a serlo y por lo tanto habría que prestarles especial atención.



• CIBERSEGURIDAD INDUSTRIAL - ENDESA

► CIBERSEGURIDAD DE UNA SUBESTACIÓN AT/MT ◀
DE ÚLTIMA GENERACIÓN

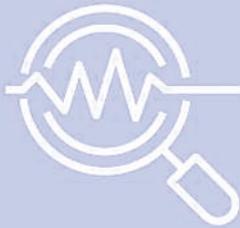
VERANO 2020

Alumnos:

Manuel Álvarez-Requejo Heredero,
Marta Casas Avery,
Rocío Giner Conde,
Raquel González Felipe,
Javier Jarauta Gastelu

Tutores:

María Avery Fernandez,
Javier Jarauta Sánchez



1. ANTECEDENTES Y ESTADO DEL ARTE

Los **ciberataques son actos en los que se cometen daños, perjuicios o agravios sobre un sistema o empresa**, y que habitualmente se suelen realizar mediante dispositivos electrónicos a través de internet. Para poder realizar un correcto análisis de los motivos, probabilidades y consecuencias de un ciberataque, **es necesario sentar las bases y realizar un análisis de los diferentes factores que influyen en la ciberseguridad**.

En el presente trabajo se va a realizar el estudio de posibles **ciberataques a una subestación de alta tensión de última generación**.

1.1. Vectores de ataque y superficie de exposición

Un **vector de ataque es el método que se utiliza en un ciberataque** para cometer el daño o agravio sobre empresa objetivo, sus personas y/o su sistema tecnológico. Además, **la superficie de exposición se puede definir como el conjunto de vulnerabilidades que existen en una organización que pueden ser susceptibles de ser atacadas** por agentes externos o internos.

Al realizar el estudio inicial, se ha analizado la superficie de exposición de la subestación, tanto a nivel interno como externo, y se han encontrado los siguientes escenarios de ataque principales que podrían afectar a la misma:

Ataques Externos

- Acceso no autorizado dentro de la subestación
- Acceso a las redes de comunicación entre central y subestación
- Acceso remoto a los activos de la subestación

Ataques Internos

- Acceso físico no autorizado
- Ataque remoto no autorizado

Es importante tener en cuenta, que muchos de estos vectores de ataque, **pueden ser no intencionados, es decir derivados de errores en la operación sin intención de atacar, pero cuyo impacto puede llegar a ser similar a los de un ciberataque**, y por ello es importante estudiarlos desde el punto de vista de la ciberseguridad.

1.2. Malware utilizado contra el sistema eléctrico

Entre los ataques pasados más importantes contra el sistema eléctrico, destacan los ataques realizados a través de *malware* diseñado específicamente para este sector, entre los que destacan los siguientes:

- **Malware "BlackEnergy"**¹
- **Malware "Industroyer"**²
- **Malware "LookBack"**³
- **Stuxnet, Triton/Trison/Trisis, Havex, Not-Petya, Petya**

Todos estos *malware* destacan por estar **focalizados en su gran mayoría en la resiliencia** del sistema, es decir, intentan mantenerse ocultos en el sistema de la empresa, **y tienen como objetivo la destrucción irrecuperable de activos**, de manera que la única solución es la sustitución de los elementos afectados por el *malware*. Además, cada vez más, estos *malware* están destinados específicamente a sistemas de control industrial.

1.3. Ataques al sistema eléctrico

Asimismo, el análisis de la situación actual se ha focalizado en ataques pasados al sistema eléctrico, destacando los siguientes:

- **Ataque Red Eléctrica Ucraniana (2015/16)**
- **Ataque a central nuclear surcoreana KHNP (2014)**

El ataque más conocido, a la **red eléctrica de Ucrania**, destaca por ser un ataque muy focalizado y orientado a la destrucción específica de los sistemas de control de la red eléctrica. El *malware* utilizado en este caso fue BlackEnergy, causando grandes estragos. En el otro extremo encontramos **el ataque en Corea del Sur**, en el que a través de las credenciales de un empleado, se accedió a la base de datos de empleados e información confidencial, solicitando como recompensa el cierre de una central nuclear.

1 Kaspersky; Blackenergy APT Attacks in Ukraine;
<https://www.kaspersky.com/resource-center/threats/blackenergy>

2 ESET; WIN32/Industroyer (Junio, 2016);
https://www.welivesecurity.com/wp-content/uploads/2017/06/Win32_Industroyer.pdf

3 Barraco, Lauren; What You Need to Know About LookBack Malware & How to Detect It (Agosto, 2019)
<https://securityboulevard.com/2019/08/what-you-need-to-know-about-lookback-malware-how-to-detect-it/>



2. OBJETIVO Y ALCANCE

En la actualidad, cada vez más **empresas están realizando una digitalización de sus activos y procesos, en un nuevo tipo de industria que se denomina Industria 4.0**, y Endesa en este caso, incluye la digitalización de las subestaciones de Alta/Media tensión como una prioridad para su futuro. Sin embargo, esta modernización puede acarrear ciertos riesgos que no existían anteriormente por la hiper-conectividad que implica ésta digitalización.

A medida que se va digitalizando la industria, la probabilidad de sufrir un ataque cibernético es cada vez más alta, con una superficie de ataque cada vez mayor. Esta situación pone en riesgo todos los años a múltiples sectores de la industria. Por ello, **la ciberseguridad es un tema que toda empresa debe tener en cuenta**, para así estar preparado y poder prevenir estos ataques, y en caso de sufrírselos, disminuir su impacto.

El objetivo de este proyecto es analizar la ciberseguridad global de una subestación eléctrica de Endesa. De esta manera, se proponen diversas mejoras en el sistema que ayuden a incrementar la madurez en ciberseguridad de la subestación, tanto en el ámbito del sistema como en el ámbito del personal de empresa. Para ello, **el proyecto presenta las siguientes fases:** levantamiento de activos, análisis de riesgos, y examen de los resultados, para poder llegar a las recomendaciones finales.

3. ANÁLISIS DE ACTIVOS, PROCESOS Y PERSONAS

En esta sección se **estudiarán los activos principales que interfieren en el funcionamiento de una subestación** y que son susceptibles a un ciberataque. A continuación, en la Ilustración 1 se muestra un **mapa de activos de la subestación** y en la siguiente Ilustración 2 **su clasificación en la arquitectura ISA**, la cual va a ser de gran utilidad para el análisis de riesgos y recomendaciones.

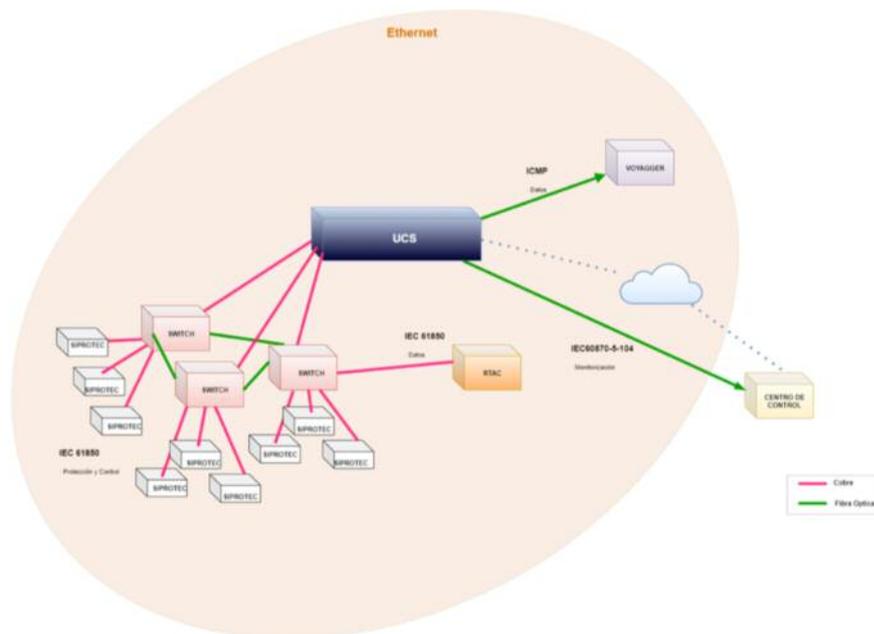


Ilustración 1: Mapa de principales activos

Una subestación está normalmente compuesta por **dos subredes de comunicación**:

- La primera de ellas conecta la UCS al centro de control a través de un rúter. Esta red utiliza **protocolos de TCP/IP para las comunicaciones y permite el acceso remoto a la subestación**.
- La segunda subred, es un circuito cerrado al que no se puede acceder desde el exterior. Este se encarga de **controlar todo lo que ocurre dentro de la subestación**. La única manera de comunicación entre ambas subredes es a través de la UCS, dispositivo de control de la subestación.

A continuación, **se explicarán estos activos** según el nivel al que correspondan en la pirámide ISA, incluyendo en este análisis sus posibles vulnerabilidades.

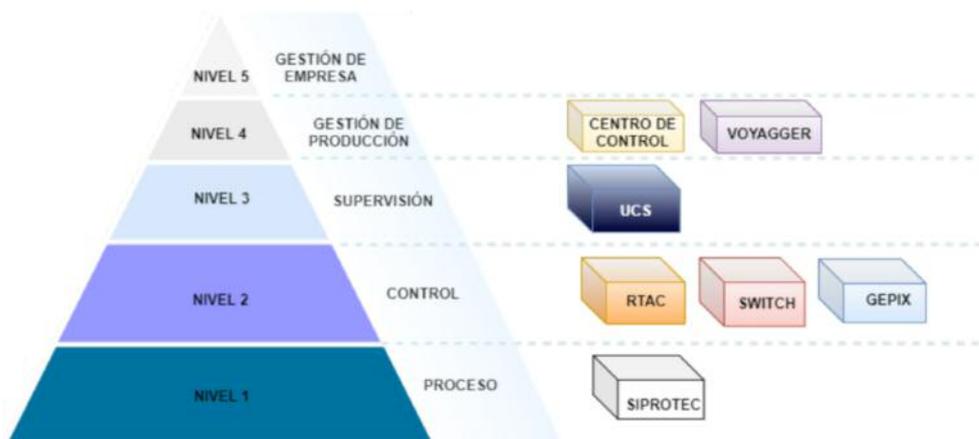


Ilustración 2: Arquitectura ISA

3.1. Activos

3.1.1. Siprotec 5 - Nivel 1

El **Siprotec 5** funcionará como **control de posición y relé de protección**. Su función es **controlar, proteger, monitorizar y tomar las principales medidas** de los elementos de la subestación.

En el caso del Siprotec se han encontrado nueve vectores de ataque, que se pueden dividir en **tres grupos según el fin del ataque**: obtención de información, desbordamiento del *firmware* y denegación de servicio. Sin embargo, estas vulnerabilidades presentadas en el análisis de CVE se encuentran solucionadas por parte de Siemens a través de parches de seguridad.

3.1.2. RTAC y GEPIX (TGP: Terminal Gestor de Protecciones) - Nivel 2

Estos elementos poseen **dos funciones: tráfico de datos para gestión de incidencias y gestión de acceso de usuarios (teleacceso)**, además de la gestión de incidencias. En este caso, se ha realizado únicamente el estudio del RTAC por ser este utilizado en las subestaciones de nueva generación.



En el caso de este dispositivo, únicamente se han encontrado dos vulnerabilidades del tipo **denegación el servicio**, sin embargo estas **se encuentran solucionadas**.

3.1.3. Ruggedcom RS900 (Switch) – Nivel 2

Este elemento se encarga de **monitorizar el campo de datos de la red interna** de la subestación y realizar el envío de paquetes entre los diferentes dispositivos. Es un intermediario para el **tráfico de telecontrol** entre la UCS y el resto de los elementos de la subestación. Este dispositivo dispone de medidas de mitigación de ciberataques, por ser un elemento de conexión TCP/IP.

Tras el análisis de las vulnerabilidades de CVE se han encontrado dos vulnerabilidades de **acceso por puerta trasera** con un compromiso total del dispositivo. Sin embargo, estas vulnerabilidades se encuentran debidamente solventadas mediante actualizaciones del dispositivo.

3.1.4. Unidad de control de la subestación (UCS) – Nivel 3

Este activo se encarga de la **gestión continua de los datos de la subestación y de la comunicación con el centro de control**. El elemento posee la monitorización completa de la subestación y realiza funciones de control y DMZ, entre otras. Se trata de un elemento que actúa como unidad maestra para el control de las comunicaciones a los despachos con todas las UCP y con el terminal local. La unidad requiere cumplir una fiabilidad y robustez mínima, ya que administra la mayor parte de la información, siendo un activo de alto nivel de confidencialidad.

3.2. Personas

Personal operador

Se trata de personal subcontratado, externo a Endesa, que sólo puede acceder al PC de mando local para **consultar el estado de la instalación** (estado de interruptores, seccionadores, valores de medidas de tensión, intensidad, etc..) y maniobrar sobre estos activos. Este personal no presenta, en un principio riesgo suficiente como para que la subestación se vea comprometida con sus actos.

Personal mantenimiento de telecontrol y protecciones

Se trata de personal subcontratado, externo a Endesa. Puede acceder al PC de mando local para **recuperar información** sobre el histórico de alarmas y eventos, curvas históricas, etc... En este caso, sus acciones podrían causar cierta afectación de manera local, pero no suponen un elevado riesgo.

Administrador del sistema

En este caso, podría tratarse tanto de personal subcontratado como de personal interno de Endesa. Puede **cargar configuraciones y bases de datos** en UCS, protecciones, PC de mando local, etc... El administrador del sistema tiene poder suficiente en la subestación como para crear un ciberataque, por lo que será un importante objeto de estudio en el análisis de riesgos.

3.3. Procesos

Parcheado de activos

Para el funcionamiento óptimo de la subestación y el mantenimiento de su seguridad, es necesario el parcheado de activos con las últimas actualizaciones. En este proceso se ha identificado que pueden

existir dos riesgos principales, la **obtención de parches maliciosos, o la existencia de malware en los dispositivos que realizan dichos parcheados**, que puedan ser traspasados a los propios dispositivos. Este proceso es realizado por el administrador del sistema siguiendo los protocolos del fabricante.

Comunicación entre centro de control y subestación

El otro proceso que puede acarrear ciertos riesgos **es la comunicación entre el centro de control y la subestación**. Las órdenes se reciben a través de enlaces TCP/IP y es la UCS la encargada de gestionarlos y ejecutarlos. Por tanto, si se viese dicha conexión o la UCS vulnerada, **las instrucciones y el estado de la subestación podría ser desconocidos** y causar problemas de funcionamiento.

4. ANÁLISIS DE RIESGOS

Para conocer las **amenazas potenciales** es necesario realizar un análisis de los riesgos que existen en el sistema, las personas y los procesos. Para ello se han realizado los análisis, Mosler, NIST.

4.1. Análisis Mosler

En primer lugar, se ha desarrollado el Método Mosler. Este estándar **identifica, analiza y evalúa** las distintas **consecuencias** de una posible incidencia o ataque, en este caso a la subestación. Con este método, se estudia la gravedad del riesgo y la probabilidad de que éste ocurra. La metodología presenta las siguientes fases: **definición, análisis, evaluación y cálculo y clasificación del riesgo**.

En la definición se procede a **identificar** los riesgos que posee cada activo. En segundo lugar, se **evalúa** el riesgo de acuerdo con los parámetros de **función, sustitución, profundidad, extensión, agresión y vulnerabilidad**. En la **evaluación**, se realizan los cálculos pertinentes del **carácter de riesgo, cálculo de la probabilidad y cuantificación del riesgo**. Finalmente, se procede a **clasificarlo en una escala**, de riesgo muy bajo a riesgo elevado.

Tras realizar el **análisis de riesgos a través de la metodología Mosler**, se puede observar que el **activo físico más crítico es la UCS**, siendo el activo con más control dentro de la subestación, teniendo asimismo comunicaciones con la red global de Endesa. En cuanto al personal con más riesgos es el administrador, ya que es capaz de realizar acciones con gran autoridad dentro de la subestación.

4.2. Análisis NIST

El NIST es el instituto nacional de estándares y tecnologías americanas. **Esta organización define una serie de preguntas a responder por la empresa para determinar el nivel de ciberseguridad de la compañía**. Este estudio se divide en cinco bloques:

- **Identificación:** *Determinar los sistemas, activos, datos y competencias, los recursos que soportan las funciones críticas y los riesgos de ciberseguridad que afectan este entorno.*
- **Protección:** *Desarrollar e implementar las contramedidas y salvaguardas necesarias para limitar o contener el impacto de un evento potencial de ciberseguridad.*



- **Detección:** Desarrollar e implementar las actividades apropiadas para identificar la ocurrencia de un evento de ciberseguridad a través de la monitorización continua.
- **Respuesta:** Definición y despliegue de actividades para reaccionar frente a un evento de ciberseguridad identificado y mitigar su impacto.
- **Recuperación:** Este bloque permite el despliegue de actividades para la gestión de resiliencia y el retorno a la operación normal después de un incidente.

Tras realizar dicho análisis, se obtuvieron los siguientes resultados. **La puntuación actual de la empresa es de 2,9 sobre 5, mientras que el objetivo a alcanzar es una puntuación aproximada de 4,2 sobre 5.**



Ilustración 3: Nivel de madurez NIST

Ese resultado se desglosa en la Ilustración 3 realizada mediante la aplicación Polar. En este se puede observar que **la detección es la sección más vulnerable** con una puntuación de **2,4 sobre 5**. Esta está proseguida por las secciones de protección e identificación en cuanto a vulnerabilidad. Estas serán principalmente las áreas por mejorar en el ámbito de Endesa.

4.3. Análisis de la situación actual de la compañía

En el ámbito interno de la empresa, Enel posee unas **directrices en ciberseguridad de obligado cumplimiento para los dispositivos y departamentos**. Tras realizar un **análisis de los 119 requisitos**, se ha procedido a realizar una criba de aquellos puntos de importancia alta, de importancia media y de menor importancia, a implementar conjuntamente con otros requisitos. Se han obtenido así **19 directrices de alta importancia, 57 de media importancia y finalmente 43 con menor importancia**. Estas directrices se incorporarán en las recomendaciones finales según su prioridad.

5. RECOMENDACIONES

Tras el estudio realizado, se han **desarrollado recomendaciones para mantener el sistema ciberseguro**. Estas recomendaciones son las que han resultado más urgentes, y se pueden interpretar como proyectos a emprender por la empresa o fallas a tener en cuenta para futuros proyectos, se dividen en relativas al personal, al sistema y a proveedores.

La **jerarquización y monitorización de accesos** es un punto muy relevante para evitar intrusiones, manteniendo así un **registro de quién, desde dónde, cuándo y cómo se ha producido el ataque**.

1. Tener una **figura responsable de accesos**.
2. El **personal externo debe estar acompañado** por personal interno de la empresa.
3. **La sala** debe estar constantemente **monitorizada**.
4. **Los accesos deben ser monitorizados en todo momento**.
5. **Instalación de un Firewall** que ayude a la monitorización de paquetes de datos.
6. **Sistemas de autenticación de dos factores:**
 - 6.1. Control de acceso a la sala mediante una **tarjeta**.
 - 6.2. Control de acceso al sistema mediante una **contraseña**.
7. **Contraseñas:**
 - 7.1. Los usuarios y contraseñas deben ser **únicas e intransferibles**.
 - 7.2. No pueden estar guardadas en el *software* o el *firmware* sin cifrar.
 - 7.3. Se deben cambiar las contraseñas cada cierto tiempo.

La **formación y concienciación del personal** reduciría los fallos debidos a errores involuntarios por no tener buenas costumbres a la hora de usar la red o no destruir correctamente los activos ya no necesarios.

1. Medidas a tomar para tener **dispositivos bien bastionados**.
 - 1.1. **Eliminación de aplicaciones y puertos innecesarias**.
 - 1.2. Utilizar sólo **protocolos de comunicación seguros** (como SSH con buen cifrado).
 - 1.3. **Análisis** de comportamiento de empleados.
 - 1.4. **Registro de eventos**.
 - 1.5. Instalar, activar y actualizar periódicamente un **agente antivirus**.
2. **Explicar la necesidad de prohibición del uso de teléfonos móviles dentro de una subestación** o incluso, **eliminar la cobertura dentro de esta**.
3. Importancia de tener **copias de seguridad**.
4. Conocimiento del **plan de actuación** en caso de ciberataque de todo el personal
5. Tener especial cuidado con la **información sobre la empresa** que le llega al exterior.

La **arquitectura del sistema** correcta permite mitigar la afección e intrusión de un ciberataque.

1. **Levantamiento de activos** y correcto inventariado.
2. **Seguridad física**.
 - 2.1. Implementación de **medidas de acceso y seguridad electrónicas**.
 - 2.2. **Control, autorización, acompañamiento y monitorización** de los empleados que acceden a la subestación.

3. Segmentación de la subestación.

- 3.1. **División en las siguientes zonas:** confianza, no confianza y DMZ.
- 3.2. **División de los activos según el criterio ISA o Purdue, clasificación de su criticidad y funciones.**

4. Firewalls.

- 4.1. Implementación de **firewalls entre niveles y en la DMZ.**
- 4.2. Implementación de **whitelists** dentro de los *firewalls*.

5. DMZ.

- 5.1. Inclusión de activos con envío de información entre niveles de producción y control dentro de la DMZ.
- 5.2. Activación de normas estrictas de entrada y salida.

6. Otras consideraciones.

- 6.1. **Conexiones externas a través de VPN** filtradas por la DMZ.
- 6.2. Segmentación a través de **VLAN.**
- 6.3. Revisión de las configuraciones por defecto.

7. Redundancia.

- 7.1. **Evita.**
- 7.2. **Técnicas de encaminamiento redundantes.**

De cara a mantener una **lista actualizada y fidedigna de los activos** presentes en la empresa, sería recomendable que se siguieran los siguientes puntos:

1. Mantener una **relación dinámica y de confianza con los proveedores.**
2. Asegurarse de que los proveedores aportan **una lista de vulnerabilidades y parches** para evitarlas.
3. Realización de **pruebas de seguimiento y confirmación** que confirmen a la compañía que los activos cumplen los requisitos expedidos.

6. CONCLUSIONES

Así es posible concluir que el desarrollo de subestaciones de nueva generación **genera que la ciberseguridad tome un papel importante y vital.** En estas, se aumenta la superficie de exposición y por tanto, es necesario mejorar el nivel de madurez. Para abordar esta mejora, **se ha realizado un levantamiento de activos, análisis de riesgos, medida del nivel de madurez y selección de las principales recomendaciones.** Es posible de esta manera ultimar que el resultado de este trabajo es **una lista de recomendaciones priorizadas y de implantación urgente destinadas a mejorar la ciberseguridad de la subestación,** con el fin de minimizar riesgos y el impacto de un ciberataque.

2. ESTADO ACTUAL DE LAS LÍNEAS DE INVESTIGACIÓN

Desde septiembre de 2020, las líneas de Destreza Robótica, la de Visión Artificial y la de Analítica Avanzada en la red de distribución, que por su extensión no pudieron ser cerradas en la edición de verano, siguen su recorrido aún en el momento de la redacción de estas líneas.

Destreza Robótica

Además de la definición general del reto, Grupo Antolin ha cedido a la Cátedra todas las piezas necesarias para reproducir el problema en los laboratorios de ICAI. Además, otro patrono de la Cátedra, ABB, ha cedido un robot IRB 14000 (más comúnmente conocido como YuMi) para poder probar las estrategias de agarre de piezas desarrolladas en el CIC LAB.

En la actualidad, el robot es capaz de reconocer el entorno procesando adecuadamente la profundidad (mediante un sensor RGB-D), identificar dónde se encuentra cada tipo de pieza que le es demandada, seleccionar cuáles son las piezas dentro del conjunto de las disponibles que más interesa coger primero, y realizar adecuadamente agarres de algunas piezas.

Visión Artificial

En esta línea de investigación, los alumnos siguen desarrollando modelos para reconocimiento de acciones y de sonidos (empleando técnicas de visión).

En el caso del reconocimiento de acciones, se han probado distintas estrategias de preprocesado de los *frames* de vídeo, se ha trabajado en la búsqueda de fuentes alternativas para aumentar las muestras del conjunto de entrenamiento y se están evaluando técnicas para poder construir sobre modelos entrenados en otros dominios.

En el caso del reconocimiento de sonido, se han comparado dos estrategias distintas de codificación de experiencia previa para poder clasificar sonidos y se ha trabajado en una estrategia de re-etiquetado de las muestras para evitar que hubiera problemas con el propio *ground truth* con el que se entrena el modelo. Como resultado, se han conseguido mejorar notablemente las prestaciones de sensibilidad y especificidad del modelo.

Analítica Avanzada en la red de distribución

En esta línea, los estudiantes, de acuerdo con el criterio de Endesa y de los investigadores del CIC LAB, se han centrado en el desarrollo de una herramienta de visualización de las magnitudes eléctricas históricas en la ciudad de Málaga. En el núcleo de esta herramienta, se ha evolucionado el enfoque de visualización del tráfico de Madrid mediante mapas de calor desarrollado por los alumnos que trabajaron en el curso 2019/20 en la línea de Logística.

Con este enfoque, se ha decidido posponer un tiempo la prueba de modelos en aras de poder disponer de una herramienta que permita al ojo humano realizar de manera eficiente los primeros análisis de los mismos. En segunda aproximación, se espera que los descubrimientos realizados tras la visualización avanzada de los datos disponibles guíen el desarrollo de modelos de analítica mucho más adaptados a la naturaleza de dichos datos.

Para ayudar a impulsar adecuadamente estas líneas, se ha incorporado a un nuevo Investigador junior al equipo de la Cátedra. Se trata de Ignacio de Rodrigo Tobías, Ingeniero de ICAI de la Promoción 2020.



FORMACIÓN

Para la Cátedra de Industria Conectada, la formación es fundamental para contribuir a **tender puentes entre la universidad y la vida profesional de los alumnos**.

El 2020 ha sido un año que nos ha puesto a prueba y nos ha hecho adaptarnos muy rápidamente para poder seguir brindando formación de calidad. Garantizando la seguridad de toda la comunidad universitaria, hemos adaptado los diferentes cursos a formatos virtuales e híbridos bimodales, lo cual ha supuesto todo un desafío para profesores y alumnos.

Este año, ha culminado la tercera edición del Máster combinado en Ingeniería Industrial e Industria Conectada (MII – MIC). A su vez, la Cátedra continúa apostando por **reforzar la formación de los profesionales en activo**, ya que son quienes pueden facilitar desde sus propios trabajos la cuarta revolución industrial. A pesar de la crisis del Covid-19, hemos culminado con éxito la tercera edición del Programa Avanzado en Industria Conectada. Liderazgo y Transformación Digital.

Otro aspecto clave a nivel formativo, ha sido la **consolidación del laboratorio de investigación e innovación (CIC LAB)**, el cual constituye un espacio destinado a los estudiantes, para que puedan aplicar sus conocimientos resolviendo problemas reales e investigar en temas relevantes para la Cátedra y la industria.

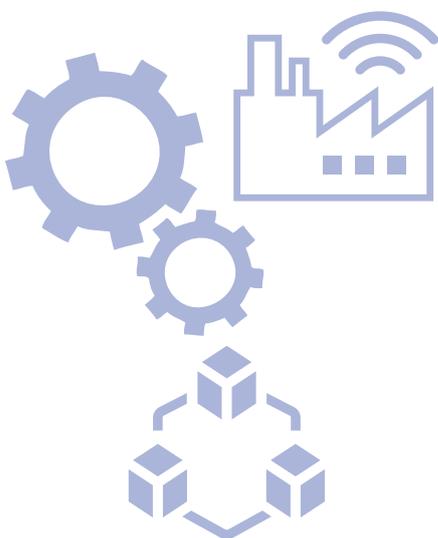
En 2021 impulsaremos nuevos programas de grado y postgrado de ICAI en el ámbito de la digitalización de la industria y en inteligencia artificial.



▶ DOBLE MÁSTER UNIVERSITARIO EN INGENIERÍA INDUSTRIAL E INDUSTRIA CONECTADA (MII-MIC)



Lidera el proceso de
transformación digital
de la industria en
contextos
internacionales



El Máster combinado formado por el Máster en Ingeniería Industrial (MII) y el Máster en Industria Conectada (MIC) permite obtener las capacidades generalistas del ingeniero industrial, a la vez que se adquiere una formación específica sobre el nuevo contexto industrial resultante de la digitalización de la industria.

Este programa se ha diseñado para desarrollar las habilidades y capacidades de ambas titulaciones en dos años. El incremento de la carga lectiva, requiere alta capacidad de organización, de estudio y de trabajo, un esfuerzo que está permanentemente guiado por profesores y tutores.

La combinación de rigor académico y prácticas en proyectos reales permite al alumno responder con solvencia a los nuevos retos de las empresas (*machine learning, big data, IoT, cloud communications, digital manufacturing, cybersecurity...*). Por otro lado, los estudiantes que obtengan esta doble titulación, además de poder colegiarse en el Colegio Nacional de Ingenieros del ICAI y ejercer la profesión regulada por ley de ingeniero industrial, serán líderes naturales del proceso de transformación digital de la industria. Además, este título también da acceso a los programas de Doctorado.

El perfil de ingreso natural es el de graduado en Ingeniería Electromecánica en la Escuela Técnica Superior de Ingeniería ICAI, ya que para garantizar la adquisición de competencias incluidas en el Máster en Ingeniería Industrial propuesto es necesario que los estudiantes accedan con las competencias, los conocimientos y los resultados del aprendizaje previamente adquiridos en el mencionado Grado. Otros perfiles de acceso naturales son los graduados en Tecnologías Industriales de otras escuelas de ingeniería.

Este título habilita para la profesión regulada de ingeniero industrial, según la normativa vigente. Así mismo el Máster en Ingeniería Industrial está enfocado de tal forma que proporciona una formación multidisciplinar e integradora, combinando la formación tradicional de los ingenieros con formación transversal para el liderazgo en contextos internacionales mediante el desarrollo de las habilidades profesionales y de comunicación.

El complemento del Máster en Industria Conectada permitirá añadir a las habilidades del Máster en Ingeniería Industrial una amplia visión de las posibilidades de las nuevas tecnologías digitales en los procesos industriales.



El doble Máster Universitario en Ingeniería Industrial e Industria Conectada proporciona una formación multidisciplinar e integradora



Robot YuMi (ABB) - CIC LAB



Las salidas profesionales más habituales de esta titulación son:

- Responsable de proyectos industriales
- Responsable de productos industriales
- Responsable de grandes instalaciones industriales
- Dirección de transformación digital
- Dirección general, técnica, estratégica o tecnológica de organizaciones
- Director de planificación, calidad, producción o gestión medioambiental
- Investigación, Desarrollo e Innovación
- Dirección de equipos multidisciplinares o internacionales
- Consultor y asesor



Alumnos del Máster en Industria Conectada

Algunos testimonios de alumnos del Máster en Industria Conectada:**Marta Bravo Lázaro:**

“ Es una oportunidad que te abre camino entre los grandes cambios y oportunidades en el sector industrial, además de poder afrontarlos en alguna gran empresa. ”

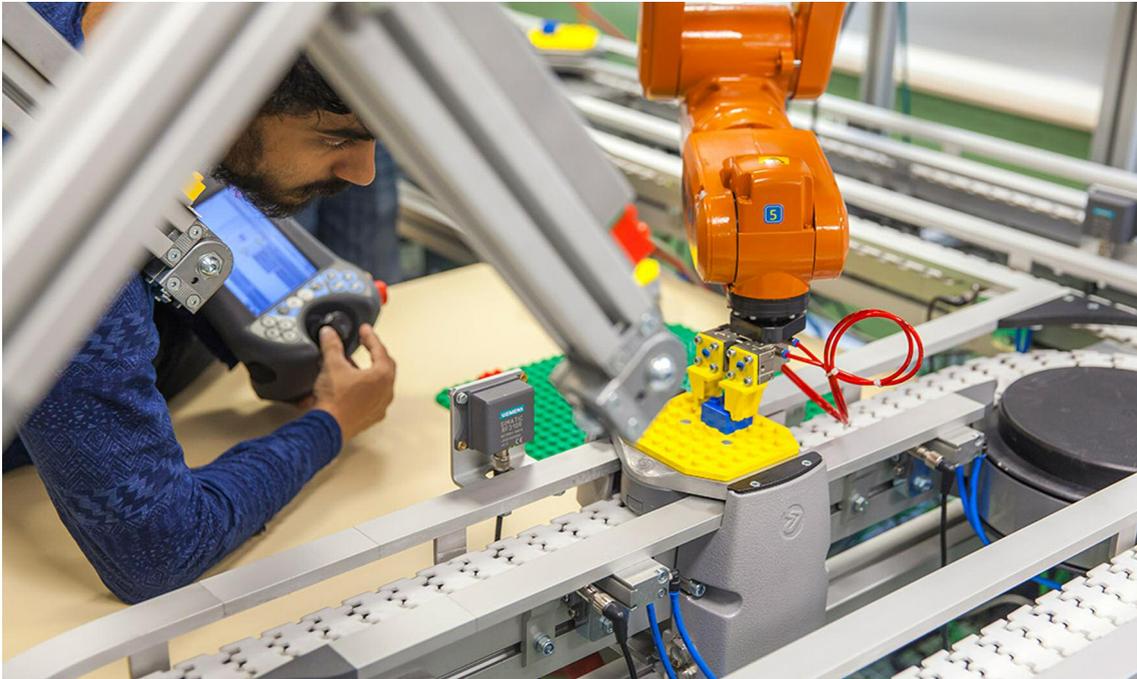
Alberto Menéndez Ruiz de Azúa:

“ El Máster en Industria Conectada me ha permitido complementar mis conocimientos y desarrollo como ingeniero industrial con una formación en transformación digital, que me permiten entender los procesos industriales desde el punto de vista de la Industria 4.0 y adaptarlos a esta nueva revolución industrial. Su marcado carácter tecnológico y práctico, junto con la inmersión en temas como el Machine Learning, Ciberseguridad, BigData o Robótica te permiten desde el primer día tener la sensación de progreso profesional y sentir que estás desarrollando destrezas que suponen un factor determinante a la hora de posicionarte en el mercado laboral. Sin duda un Máster que recomiendo a cualquier ingeniero que quiera adaptar sus conocimientos a las nuevas tecnologías disruptivas que están transformando la industria y con ganas de liderar el cambio hacia la digitalización que se está produciendo en el sector industrial. ”





PROGRAMA AVANZADO EN INDUSTRIA CONECTADA. LIDERAZGO Y TRANSFORMACIÓN DIGITAL

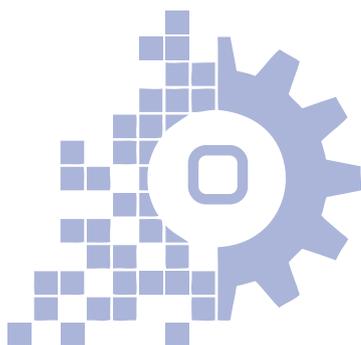


Para Bernardo Villazán, codirector de la Cátedra de Industria Conectada y director del Programa Avanzado, “la transformación digital no es una tendencia, es visión, es estrategia, cultura organizativa, rediseño de procesos”.

Según diferentes estudios, España se sitúa por debajo de la media europea y fuera del Top 40 mundial en lo que respecta a digitalización, tanto a nivel individual como empresarial. Por eso, la Cátedra de Industria Conectada ha puesto en marcha una nueva edición del pionero “Programa Avanzado en Industria Conectada. Liderazgo y Transformación Digital”.

Este Programa nace a partir del Máster en Industria Conectada (60 ECTS), dirigido a graduados en ingeniería de la rama industrial sin experiencia profesional, y tiene por objetivo ofrecer formación sobre transformación digital de empresas industriales a profesionales con experiencia de entre 4 y 8 años.

Este innovador programa consta de más de 200 horas lectivas –entre teoría, práctica, encuentros con directivos y visitas a empresas–, por reconocidos profesionales de compañías líderes del sector en estrategias digitales.



Para ser admitido al Programa es necesaria una carta de presentación que incluya información relevante sobre la formación y experiencia del candidato. El proceso de admisión cuenta además con una entrevista personal con el director del Programa Avanzado. La salida profesional natural es de director de transformación digital.

El reto pasa por repensar los modelos de negocio y las cadenas de valor basándonos en un mercado que cambia muy deprisa y en el que nos enfrentamos a competidores cada vez más ágiles. Por su parte, Mariano Ventosa, codirector de la Cátedra y vicerrector de Investigación e Internacionalización de la Universidad indica que “en el mundo actual se abre un nuevo campo a explorar y son necesarios nuevos conocimientos y formación para afrontar con garantías de éxito la transformación digital: un cambio que implica nuevas formas de trabajo con plataformas digitales y colaborativas, con nuevas estrategias de engagement y nuevas fórmulas de atracción y gestión del talento, una nueva mentalidad hacia el trabajo que repercute en la forma de hacer negocios, no sólo en los procesos”.



Profesionales en una de las sesiones del Programa Avanzado en Industria Conectada, Liderazgo y Transformación Digital.

La tercera edición del Programa Avanzado ha concluido en junio con 19 graduados, y en octubre hemos dado comienzo a la cuarta edición. A partir del 2020, el programa ha comenzado a impartirse en un sistema bimodal presencial y remoto a la vez, garantizando así todas las medidas de seguridad, y brindando la oportunidad a que profesionales de todas partes de España puedan inscribirse.



Javier Jarauta, Director de Consultoría de Grupo SIA, director del Máster en Ciberseguridad de la ETSI ICAI y miembro del claustro de profesores del Programa Avanzado destaca la importancia de contar con unos fundamentos sólidos para poder desenvolverse con éxito en el nuevo entorno cambiante de la industria y la economía digital.

El Programa Avanzado sigue causando gran satisfacción en el alumnado. De hecho, los 20 participantes en la cuarta promoción se graduarán en el primer trimestre de 2021.



Alumnos del Programa Avanzado en Industria Conectada, Liderazgo y Transformación Digital.

Algunos testimonios de alumnos que han realizado el programa:**David Linares, PLADUR GYPSUM S.A.U. Export Manager:**

“ El programa de Liderazgo para la Transformación Digital es ideal para personas que quieran tener una visión global de las nuevas tecnologías que afectan con su disrupción al mundo de los negocios convencional y las nuevas formas de trabajar (Agile). Lo recomiendo a Seniors que tienen que tomar responsabilidades digitales viniendo de áreas no digitales y profesionales con un mínimo de experiencia de 5 años que quieren iniciar su andadura profesional en este campo. El alto nivel de los ponentes, una cuidada selección de alumnos, además del complemento de los almuerzos con el CEO y las visitas a industrias disruptivas han cambiado mi manera de ver los negocios. Ha sido la palanca para dar un salto mental y obtener resultados por encima de los crecimientos incrementales. ”

María José Franco, Structuring, ENDESA:

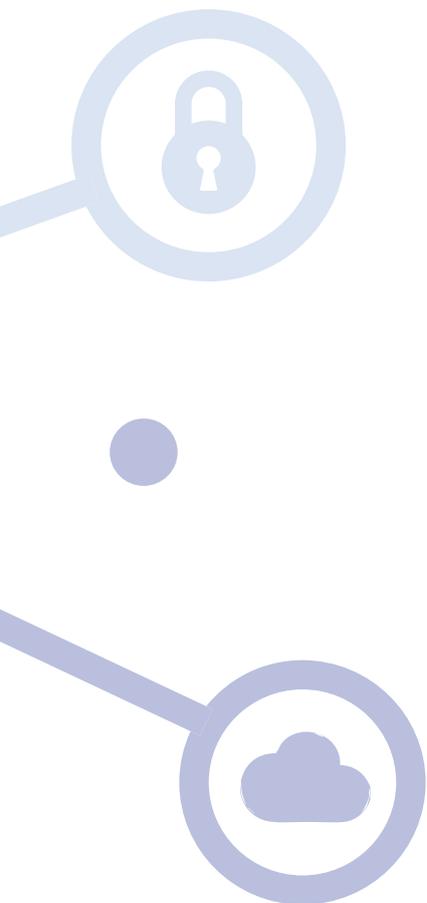
“ Participar en el Programa Avanzado en Industria Conectada ha sido una oportunidad tanto de aprender como de relacionarme con excelentes profesores y profesionales. Además, me ha generado curiosidad y ganas de continuar profundizando en muchas de las materias y, sobre todo, de mantenerme al día en este entorno cambiante. ”

Miguel Canga, IBERIA Vendor Control Manager:

“ Una buena combinación entre teoría y práctica donde la red de conocimiento que se forma entre los alumnos, cada uno con una formación y procedente de un sector diferente, se convierte en unos de los activos de mayor valor del programa. Es espectacular cómo las experiencias previas en retos de transformación y la apertura de pensamiento que el programa genera hacen que los debates, durante y después del programa, se enriquezcan notablemente y nos permitan llegar a soluciones antes inexploradas. ”







COMILLAS
UNIVERSIDAD PONTIFICIA

ICAI

ICADE

CIHS

© Universidad Pontificia Comillas

EDITA:
Cátedra de Industria Conectada

DISEÑO Y REALIZACIÓN:
Alcuadrado, Diseño y Comunicación, S.L.



comillas.edu