



Facultad de Ciencias

**Optimización de la investigación en
estudios alimenticios a través de una
herramienta inteligente para el análisis de
datos**

**(Optimization of research in nutritional
studies through intelligent data analysis tools)**

Trabajo de Fin de Máster
para acceder al

MÁSTER EN DATA-SCIENCE

Autor: Pablo Izquierdo González

Director\es: Lara Lloret Iglesias y Miriam Cobo Cano

Febrero - 2024

AGRADECIMIENTOS

Me gustaría expresar mi gratitud a varias personas que de no haber sido por ellas, este trabajo de fin de master no se hubiera podido llevar a cabo. En primer lugar a mi familia, en especial a mi hermana Elena, por acompañarme en esas tardes de intenso trabajo llenas de cafeína. A mis directoras, Lara y Miriam, por su dedicación y apoyo incondicional durante todo el proceso de tutoría. También quiero agradecer profundamente a mis compañeras en los diferentes institutos que forman parte del proyecto DigitalAlimenta, por su paciencia y colaboración constante a lo largo del desarrollo de este trabajo.

Quiero agradecer el apoyo al Ministerio de Ciencia e Innovación a través de los proyectos PID2019-108851RB9 y Prueba de Concepto PDC2922-133861

No puedo dejar de mencionar a mis compañeros de despacho y a los miembros del grupo de computación del IFCA, así como a los responsables del CPD, por toda la valiosa ayuda y el soporte técnico brindado en cada etapa del proyecto.

Por último, pero no menos importante, deseo expresar mi gratitud al proyecto AI4EOSC por proporcionarme la plataforma necesaria para llevar a cabo este trabajo. Sin su invaluable contribución, este proyecto no habría sido posible. Asimismo, quiero reconocer y agradecer a todos los involucrados en el desarrollo de este proyecto, especialmente a aquellos que me han asistido en la resolución de problemas técnicos y han hecho posible la realización de este trabajo.

RESUMEN

La alimentación actual ha decaído en comparación con generaciones anteriores. La prevalencia alarmante de comida rápida, snacks y refrescos carentes de nutrientes es notoria. Este comportamiento ha llevado a dietas desequilibradas, con exceso de grasas, carnes y falta de nutrientes esenciales. Surge una necesidad urgente de sensibilizar a la sociedad y proporcionar una herramienta orientativa para mejorar la calidad de la alimentación, al tiempo que facilite a los investigadores la realización de estudios alimenticios.

Con el auge de la inteligencia artificial y la versatilidad de las redes neuronales, se busca aplicar este campo de la informática al problema alimenticio de la sociedad. Un ejemplo de ello es el proyecto "WineGut_BrainUP", que utilizó redes convolucionales para determinar la cantidad de vino en una copa mediante una imagen, con el objetivo de obtener medidas más precisas para su uso en estudios alimenticios. En línea con este enfoque, se aspira a implementar una herramienta similar para predecir el peso de ciertas frutas como continuación a este proyecto.

Por ende, como resultado de este trabajo de fin de máster, se pretende desarrollar la mencionada herramienta, además de implementar una herramienta de recogida de datos que proporcione consejos alimenticios a los usuarios.

Palabras clave: DigitalAlimenta, inteligencia artificial, aprendizaje profundo, estudios alimenticios, mejorar estudios alimenticios, visión por ordenador, pérdida a través de imagen, pérdida peso manzanas.

ABSTRACT

Today's diets have declined compared to previous generations. The alarming prevalence of nutrient-deficient fast food, snacks and soft drinks is notorious. This behaviour has led to unbalanced diets, with an excess of fats and meats, and a lack of essential nutrients. There is an urgent need to raise awareness and provide a guidance tool to improve dietary quality, while facilitating dietary studies for researchers in this field.

With the rise of artificial intelligence and the versatility of neural networks, the aim is to apply this field of computer science to society's food problem. An example of this is the "WineGut_BrainUP" project, which used convolutional networks to determine the amount of wine in a glass using an image, with the aim of obtaining more accurate measurements for use in food studies. In line with this approach, the aim is to implement a similar tool to predict the weight of certain fruits as a continuation of this project.

Therefore, as a result of this master's thesis, it is intended to develop the aforementioned tool, in addition to implementing a data collection tool that provides dietary advice to users.

Keywords: DigitalAlimenta, artificial intelligence, deep learning, nutritional studies, improve nutritional studies, computer vision, perception through image, perception weight apples.

CONTENTS

1	Introducción	1
1.1	Motivación	1
1.2	Objetivos	2
1.3	Metodología	3
2	Recogida de Datos	7
2.1	Introducción	7
2.2	Herramienta Web	7
2.2.1	Requisitos	7
2.2.2	Implementación	8
2.3	Dataset de frutas	24
2.3.1	Parámetros de la fotografía	25
2.3.2	Herramientas	27
3	Modelo de aprendizaje profundo	29
3.1	Implementación	29
3.1.1	Tratamiento de los datos	29
3.1.2	Ajuste de parámetros	31
3.1.3	Reducción Overfitting	32
3.1.4	Bootstrapping	37

4 Resultados Obtenidos	39
4.0.1 Modelo Final	39
4.0.2 Entorno de Ejecución	45
4.0.3 Resultados Obtenidos	45
5 Conclusiones	49
5.1 Objetivos conseguidos	49
5.2 Trabajos futuros	49
5.3 Reflexión personal	50
Referencias bibliográficas	51

INTRODUCCIÓN

1.1 MOTIVACIÓN

La alimentación actual de la población ha experimentado un declive en comparación con generaciones anteriores. Vivimos en una sociedad caracterizada por una hiperactividad palpable, donde la atención se centra en el trabajo constante, la eficiencia y la búsqueda incesante de un futuro mejor. Esta mentalidad frenética, sin embargo, ha relegado a un segundo plano aspectos cruciales como una alimentación adecuada.

La prevalencia de comida rápida o precocinada, refrescos y snacks con etiquetas repletas de términos desconocidos, saturados de grasas y carentes de nutrientes es alarmante. Para empeorar la situación, a pesar del reconocido beneficio de la dieta mediterránea, la mayoría de las personas, absorbidas por el desenfreno de la vida moderna, optan por alternativas rápidas y convenientes para llenar sus fiambreras diarias.

Este comportamiento ha conducido a un desafortunado escenario en el que las dietas se componen principalmente de grasas, carnes, exceso de carbohidratos y carecen de alimentos ricos en nutrientes esenciales, como verduras, legumbres y pescados.

En la actualidad, la visión artificial destaca como uno de los principales campos de la inteligencia artificial, definida como **"Computer vision enables computers and systems to derive meaningful information from digital images, videos and other visual inputs."** [6]. Este campo se centra en reconocer patrones en imágenes y vídeos, como lo hacen las cámaras de vigilancia al detectar personas e incluso caras. Además, esta tecnología puede entrenarse para realizar tareas complejas que van más allá de las capacidades visuales humanas.

Un ejemplo de la aplicación de la visión artificial aplicada a la alimentación se encuentra en el proyecto "WineGut_BrainUP" [3], cuyo objetivo es obtener datos con mayor precisión, con respecto al volumen de vino ingerido, que la proporcionada por los cuestionarios alimenticios convencionales. Estos cuestionarios presentan limitaciones significativas, especialmente al estipular raciones estándar para ciertos alimentos. El vino, por ejemplo, tiene una ración estándar de 200 ml, pero los usuarios pueden

ingerir cantidades menores o mayores en cada toma. Aunque una diferencia de 30 ml pueda parecer insignificante, la falta de precisión en los datos impacta notablemente en los resultados de un estudio alimenticio. Durante la realización de estos se busca calcular con la máxima exactitud posible los macro y micro nutrientes de un individuo, con el fin de identificar relaciones entre ciertos alimentos y enfermedades.

En este contexto, DigitalAlimenta es un proyecto que surge de la necesidad urgente de sensibilizar a la sociedad sobre el problema alimenticio y poner a disposición una herramienta que brinde orientación para mejorar la calidad de la alimentación, mientras facilita y optimiza la realización de estudios alimenticios para los investigadores en este campo.

1.2 OBJETIVOS

En respuesta a lo mencionado anteriormente, este Trabajo Fin de Máster se enfoca en el proyecto DigitalAlimenta, que se basa en el proyecto "WineGut_BrainUP". Los objetivos principales del proyecto DigitalAlimenta son los siguientes:

- Desarrollar una herramienta web que ofrezca orientación para mejorar la calidad de la alimentación.
- Crear una herramienta de inteligencia artificial para determinar el peso de las cuatro frutas más comunes en España (Manzana, Pera, Naranja y Plátano).

Sin embargo, dada la complejidad del problema, este Trabajo Fin de Máster se enfocará exclusivamente en la creación de la herramienta web y la implementación de la inteligencia artificial para determinar el peso de las manzanas. Ambas herramientas involucran la aplicación de diversas tecnologías, desde Python, SQL y Keras, aprendidas durante el máster, hasta otras como Flask, HTML, CSS y JavaScript.

1.3 METODOLOGÍA

Una vez que se han establecido los objetivos que este proyecto busca lograr, es esencial definir el procedimiento que se seguirá para alcanzar de manera satisfactoria dichos objetivos. Por este motivo, he optado por emplear un ciclo de vida de proyecto que sigue un modelo iterativo incremental. Este enfoque intermedio combina las ventajas de los modelos de cascada y de desarrollo evolutivo.

La metodología de cascada fue propuesta por Winston W. Royce en 1970 en su ensayo titulado *Managing the development of large software systems* [10]. Royce propone un modelo compuesto por siete fases, las cuales se pueden observar en la Figura §1.1. Sin embargo, este método es rígido y los cambios significativos resultan costosos.

En la práctica, se han realizado algunas modificaciones a este modelo para reducir el número de fases, como se menciona en la publicación [11], que destaca solo 5 fases. En la fase de análisis y definición de requerimientos, se establece contacto con los clientes y usuarios finales para determinar las metas de la aplicación y los servicios que debe proporcionar el sistema, además de sus restricciones. La fase de diseño del sistema y del software se encarga de identificar y describir los subsistemas además de la relación entre estos. Posteriormente, se procede a codificar y probar los subsistemas por separado, conformando la fase de implementación y validación. La etapa de integración y validación del sistema consiste en unir los programas o unidades individuales para formar un sistema completo que cumpla con los requerimientos del software. Una vez superadas las pruebas, se entrega el producto al cliente. La última etapa implica la instalación y puesta en funcionamiento del sistema, junto con mantenimientos periódicos para corregir errores no detectados en etapas anteriores y mejorar la implementación del sistema.

El método evolutivo permite a los ingenieros de software desarrollar una implementación inicial, considerando los comentarios de los usuarios, y mejorar el sistema a través de diferentes versiones, logrando así un sistema más adecuado con el tiempo (Figura §1.2) [11].

El enfoque evolutivo suele ser más efectivo que el enfoque en cascada, ya que satisface los requisitos inmediatos de los clientes. Sin embargo, presenta dos problemas: la falta de visibilidad del proceso, lo cual requiere entregas frecuentes para medir el progreso, y la falta de rentabilidad al desarrollar rápidamente el sistema, lo que dificulta detallar cada versión. Además, la estructura a menudo es deficiente debido a los cambios continuos, lo que hace más difícil y costoso realizar modificaciones y añadir

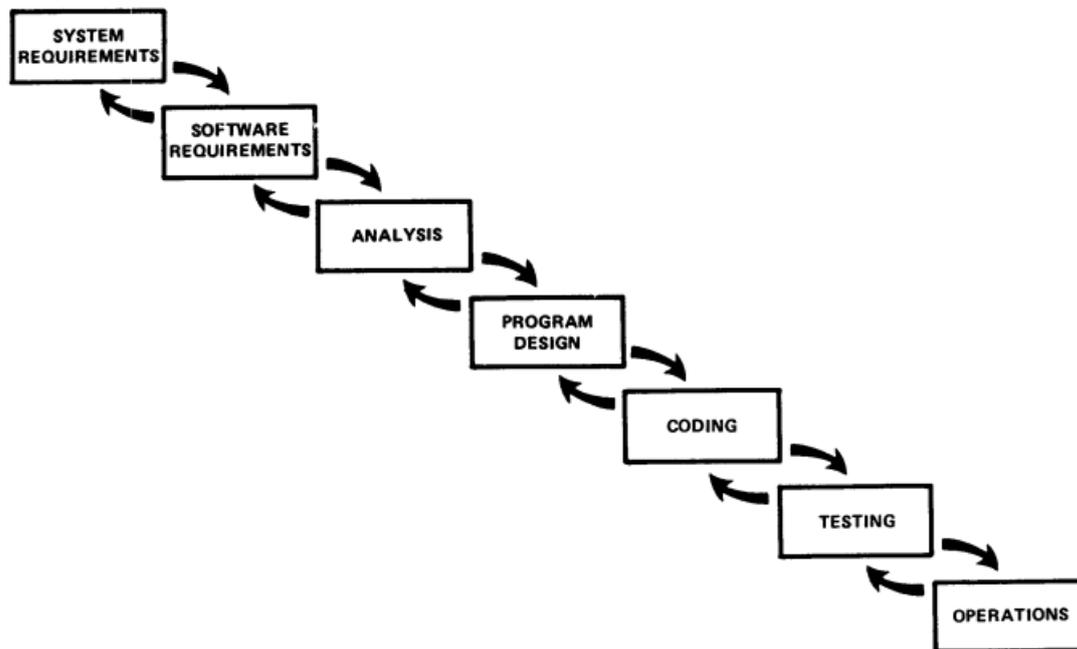


Figure 1.1: Representación de la metodología de cascada propuesta por Winston W. Royce [10]

características.

La metodología en cascada mencionada anteriormente requiere que los clientes cumplan con un conjunto de exigencias antes de entrar en la etapa de diseño, y que el diseñador emplee estrategias específicas para adaptar el diseño a las necesidades del cliente antes de la implementación. La modificación de los requerimientos implica rehacer el trabajo de captura de estos para las etapas de diseño e implementación. Dado que son etapas diferenciadas, deben resultar en sistemas bien documentados que permitan cambios. Por otro lado, el enfoque de desarrollo evolutivo, mencionado anteriormente, posibilita que los requisitos y las decisiones de diseño se retrasen, pero da lugar a un software que puede estar débilmente estructurado, lo que complica su comprensión y mantenimiento.

Un proceso de *desarrollo iterativo incremental*, como el seguido para la realización de este trabajo, tiene como objetivo entregar a los clientes un sistema funcional. Esto implica comenzar con los requisitos mejor comprendidos y de mayor prioridad. Los clientes reconocerán, de manera general, los servicios que proporcionará el sistema, identificando cuáles son más importantes. En este caso, los compañeros de diferentes institutos científicos pertenecientes al proyecto DigitalAlimenta (CIAL, ICVV, CIBIR) han asumido el papel de clientes, identificando y determinando los requisitos y necesi-



Figure 1.2: Representación de la metodología evolutiva [11]

dades del sistema. Posteriormente, se definen varios incrementos, cada uno proporcionando una funcionalidad al sistema. Los servicios que conforman los incrementos están determinados por la prioridad del servicio, garantizando que se realicen primero los de mayor prioridad. Un ejemplo de este proceso se muestra en la Figura §1.3.

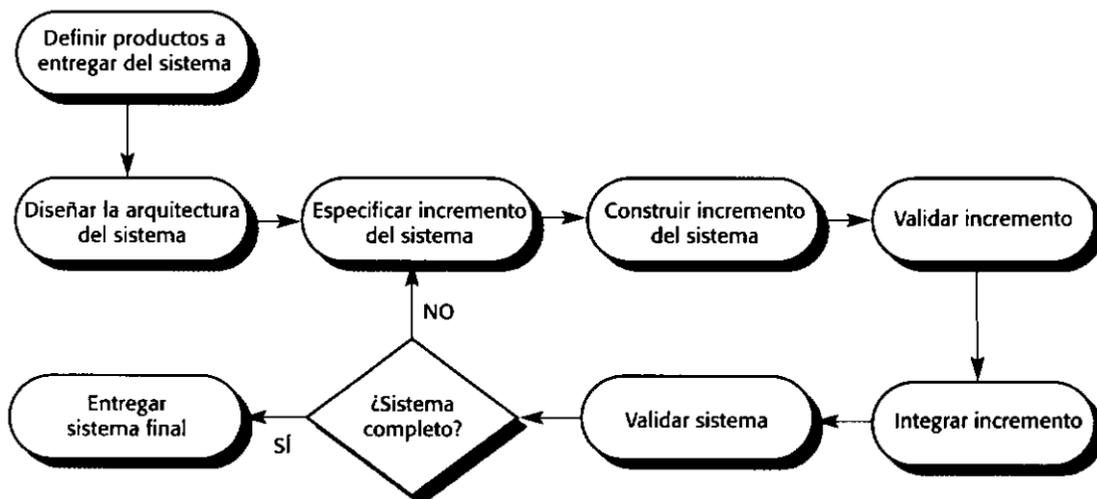


Figure 1.3: Proceso iterativo incremental [11]

La metodología iterativa incremental presenta varios beneficios. Los clientes no tienen que esperar la entrega del sistema completo para empezar a trabajar con él. Al satisfacer los requerimientos más necesarios al principio, los clientes pueden utilizarlo como prototipo y proporcionar retroalimentación sobre los requisitos para los incrementos posteriores. Esto ha permitido realizar una validación del servicio web con un pequeño grupo de voluntarios. Además, al realizar los servicios más importantes al principio, se someten a numerosas pruebas, lo que reduce la probabilidad de encontrar fallos en el producto final.

RECOGIDA DE DATOS

2.1 INTRODUCCIÓN

Como se ha señalado en la sección de objetivos, este trabajo de fin de master se puede dividir en dos partes fundamentales. En primer lugar, se ha estado desarrollando una herramienta web diseñada para ofrecer consejos sobre dietas y facilitar la recopilación de datos sobre la alimentación de los voluntarios. Esta herramienta abarca diversos aspectos, desde bebidas y frutas hasta cereales, carnes, verduras, entre otros. A través de un cuestionario en línea, se recopilan datos de los voluntarios con el propósito de medir la cantidad en gramos de cada alimento en su dieta. Estos datos se emplean posteriormente en estudios alimenticios para calcular los macro y micro nutrientes ingeridos, además de detectar posibles deficiencias o excesos de ciertos alimentos, proporcionando así información valiosa al usuario.

2.2 HERRAMIENTA WEB

En el contexto de un estudio de alimentación, la recopilación de datos se destaca como el aspecto más crucial, ya que su objetivo es medir tanto los macronutrientes como los micronutrientes para identificar posibles deficiencias o excesos. Tradicionalmente, estos datos se obtienen a través de cuestionarios que abarcan distintos tipos de alimentos y sus respectivas porciones. Siguiendo esta metodología y basándonos en un cuestionario aprobado por las instituciones pertinentes en el ámbito de la alimentación, el objetivo es digitalizar dicho cuestionario para su uso en varios estudios simultáneamente.

2.2.1 Requisitos

Una vez aclarado el objetivo de la herramienta web, se establecen los requisitos iniciales. Al emplear una metodología iterativa incremental, se permite la incorporación de nuevos requisitos durante el desarrollo, pero es esencial priorizar los más cruciales

para obtener un sistema funcional en el menor tiempo posible.

La lista de requisitos funcionales en orden ascendente de prioridad es la siguiente.

1. Proporcionar una interfaz de usuario intuitiva y de fácil uso.
2. Registrar las respuestas proporcionadas.
3. Diferenciar entre usuarios y brindar una experiencia personalizada.
4. Generar automáticamente un informe alimenticio para el usuario.
5. Mantener un historial de informes alimenticios.
6. Compatibilidad con dispositivos móviles.
7. Automatizar la extracción de datos a formato Excel.
8. Incluir un cuestionario alimenticio de 24 horas.

La lista de requisitos no funcionales es la siguiente.

1. Garantizar una disponibilidad del servicio web del 80
2. Asegurar la correcta preservación de los datos.
3. Minimizar el tiempo de respuesta de la web a 3 segundos.

2.2.2 Implementación

La implementación de los requisitos ha requerido el uso de diversas herramientas. Para el frontend, se han utilizado HTML5, CSS y JavaScript, mientras que para el backend, se ha empleado Flask, un microframework para Python basado en Werkzeug que facilita la creación rápida y sencilla de aplicaciones web. Es crucial destacar la utilización de Python y SQL, herramientas que fueron aprendidas y exploradas durante el máster, lo cual ha facilitado considerablemente la implementación de los diferentes requisitos detallados en las siguientes secciones.

Proporcionar una interfaz de usuario intuitiva y de fácil uso.

La interfaz se divide principalmente en tres partes. Una cabecera, presente en todas las páginas de la web, muestra el logo del proyecto, un botón de usuario que ofrece la opción de cerrar sesión y un panel de navegación para acceder a las diferentes secciones.

Como se puede observar en la imagen §2.1, el diseño es minimalista y autoexplicativo para facilitar su utilización. Además, se encuentra una cabecera secundaria que presenta una imagen relacionada con el proyecto, junto con un texto de presentación.

Inicio Perfil Usuario Cuestionario Informe

PATRÓN DE DIETA DIGITALIZADO

Una herramienta digital para el registro de los hábitos alimentarios de la población.
 Proyecto financiado por el Ministerio de Ciencia e Innovación (PID2019-108851RB9 y Prueba de Concepto PDC2922-133861)

CUESTIONARIO DE FRECUENCIA DE CONSUMO DE ALIMENTOS

Muchas gracias por acceder al cuestionario digitalALIMENTA para participar en un estudio de hábitos alimentarios, mediante el uso de herramientas digitales. Este estudio forma parte del proyecto de investigación 'Desarrollo y validación de un sistema de información digitalizado para la evaluación integral de hábitos alimentarios en grupos poblacionales' que tiene como objetivo promover una alimentación saludable y sostenible.

¿Qué tengo que hacer?

Si acepta participar en el estudio, tendrá que completar unos breves datos personales: sexo, edad y comunidad autónoma, así como un cuestionario completo que incluye preguntas acerca de la frecuencia de consumo de los principales grupos de alimentos y bebidas, de acuerdo con sus hábitos durante el último año. El estudio no requiere datos identificativos, con el fin de respetar al máximo su privacidad. Toda la información recogida será de uso exclusivo para el desarrollo y la mejora del cuestionario digitalizado.

¿Qué información obtendré?

Una vez cumplimentado el cuestionario, le proporcionaremos un breve informe individualizado sobre su patrón alimentario, utilizando como referencia las recomendaciones de la Sociedad Española de Nutrición Comunitaria (SENC).

¿Cómo se van a tratar mis datos?

Una vez que se registre en la plataforma, tendrá un identificador de acceso y siempre los datos aportados se tratarán como información seudonimizada, sin que puedan ser compartidos con ningún otro propósito que no sea este estudio. La información que usted nos proporcione será utilizada exclusivamente con fines orientados a la investigación, no pudiendo relacionar la misma con sus datos personales.

¿Qué condiciones debo cumplir si quiero participar?

Para participar en este estudio, el único requerimiento es ser mayor de 18 años, no padecer enfermedades conocidas, y consentir el uso de los datos aportados con fines exclusivamente científicos.

[Cuestionario](#) [Perfil Usuario](#)

CSIC CIAL IIV CIBIR IFCA
 Consejo Superior de Investigaciones Científicas Instituto de Ciencias de la Vid y del Vino Centro de Investigación Biomédica de La Rioja Advanced Computing Group

Figure 2.1: Pagina Web

A continuación de esta cabecera secundaria se encuentra el cuerpo de la web, el cual cambia dependiendo de la sección en la que nos encontremos. Por ejemplo, en la ventana inicial, esta sección recoge los términos y condiciones de la web, explicando el tratamiento y uso de los datos proporcionados.

Por último, se encuentra el pie de página, esta sección solo aparece en la ventana inicial y presenta los logotipos de las instituciones participantes del proyecto.

ESTRUCTURA DEL CUESTIONARIO WEB

El cuestionario que se intenta implementar, dispone de 160 preguntas aproximadamente, agrupadas entorno a 10 grupos de alimentos.

- Lácteos
- Huevos, Carnes, Pescados
- Verduras y Hortalizas
- Frutas
- Legumbres y Cereales
- Aceites y Grasas
- Bollería y Pastelería
- Miscelánea
- Bebidas
- Suplementación nutricional

Cada botón de la ventana del índice redirige al cuestionario correspondiente a ese grupo de alimentos (Figura §2.2). Asimismo en la ventana del cuestionario, se ha suprimido la cabecera secundaria para proporcionar una visión más clara del cuestionario. Además, se ha añadido un "índice" de círculos que se autocolorean a medida que se rellenan los cuestionarios de cada grupo de alimentos.

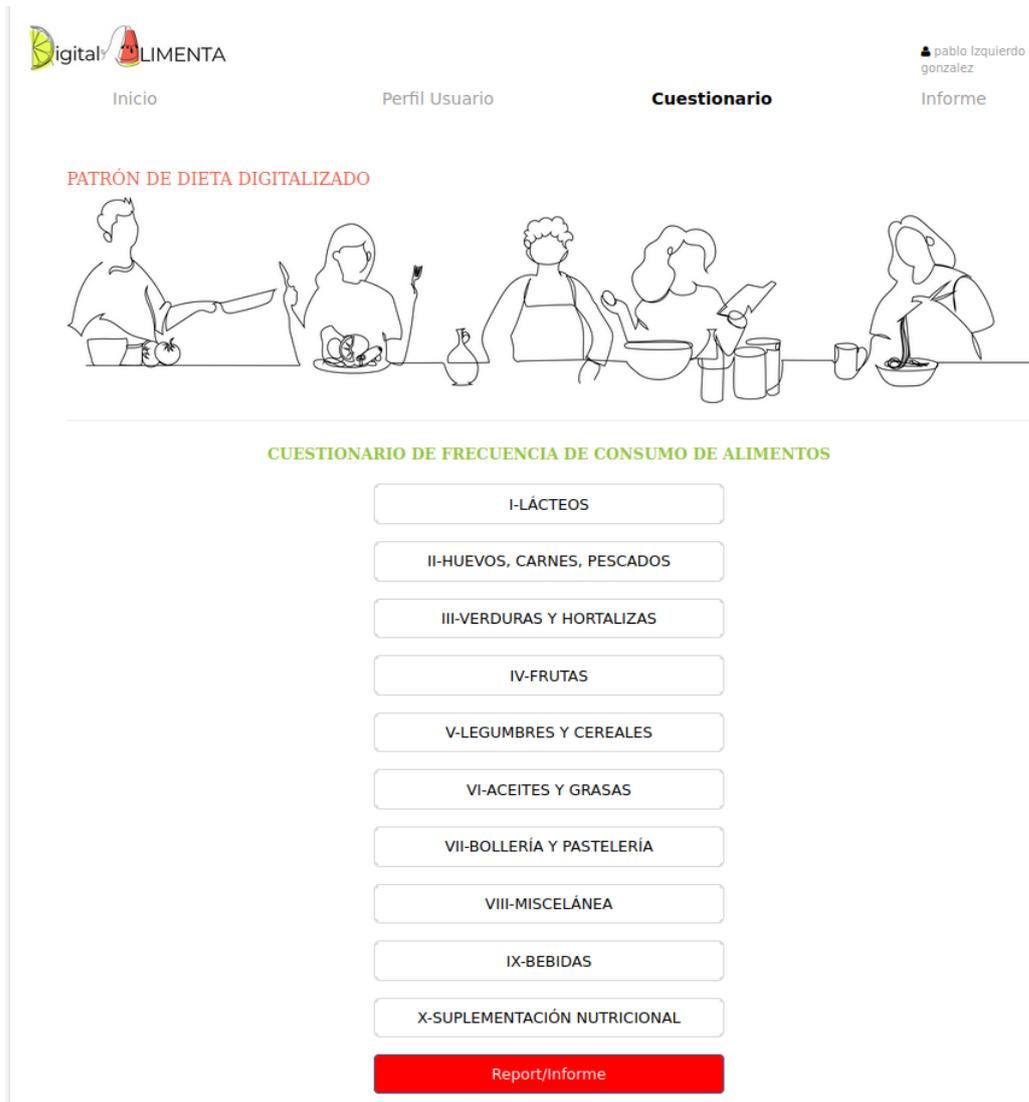


Figure 2.2: Índice Grupos de alimentos

El cuestionario en sí se presenta en formato de tabla, mostrando las preguntas y una serie de frecuencias de consumo. Es relevante destacar que cada cuestionario es único y algunos grupos de alimentos contienen preguntas "especiales" que no se contestan seleccionando una frecuencia. Este es el caso de la columna de "Estacionalidad", que proporciona ciertas opciones dependiendo de la pregunta, o como sucede en casos como productos sin lactosa o sin gluten, así como algunas preguntas que se responden con un número o introduciendo texto (Figura §2.3).

Inicio Perfil Usuario **Cuestionario** Informe

pablo izquierdo gonzalez

CUESTIONARIO DE FRECUENCIA DE CONSUMO DE ALIMENTOS

I II III IV V VI VII VIII IX X

I-LÁCTEOS	CONSUMO MEDIO DURANTE EL AÑO PASADO								ESTACIONALIDAD
	Nunca o casi nunca	AL MES	A LA SEMANA			AL DIA			
		1-3	1	2-4	5-6	1	2-3	4-6	
1. Leche entera (1 taza, 200 cc)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
2. Leche semidesnatada (1 taza, 200 cc)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
3. Leche desnatada (1 taza, 200 cc)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
4. Leche condensada (1 cucharada)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
5. Nata o crema de leche (1/2 taza)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
6. Batidos de leche (1 vaso, 200 cc)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
7. Yogurt entero (1 unidad, 125 g)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
8. Yogurt desnatado (1 unidad, 125 g)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
9. Petit suisse (1 unidad, 55 g)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
10. Requesón o cuajada (1/2 taza)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
11. Queso en porciones, cremoso o queso de untar (tipo casero o philadelphia) (1 porción o 25 g)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
12. Otros quesos: curados, semicurados (Manchego, Bola, Emmental...) (50 g)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
13. Queso blanco o fresco (Burgos, cabra...) (50 g)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
14. Natillas, flan, puding (comerciales o caseros) (1 unidad, 130 cc)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
15. Helados (1 tarrina o 1 cucurucho)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

¿Consumes estos alimentos sin lactosa? SI NO

Salir Volver **Guardar y Seguir**

Figure 2.3: Cuestionario Lácteos

Registrar las respuestas proporcionadas

En el proyecto, es esencial contar con un sistema de almacenamiento de los datos recopilados. Para ello, se ha elegido una base de datos relacional MySQL, que consta de las siguientes tablas:

- **form**: Recopila las respuestas a los formularios de los usuarios.
- **freq**: Contiene las frecuencias posibles.
- **question**: Contiene las preguntas del cuestionario, así como al topic al que pertenece cada una.
- **topic**: Contiene los títulos y cabeceras de cada grupo de alimentos.
- **users**: Recopila los datos personales de los usuarios.

A continuación, se presenta el diagrama de la base de datos:

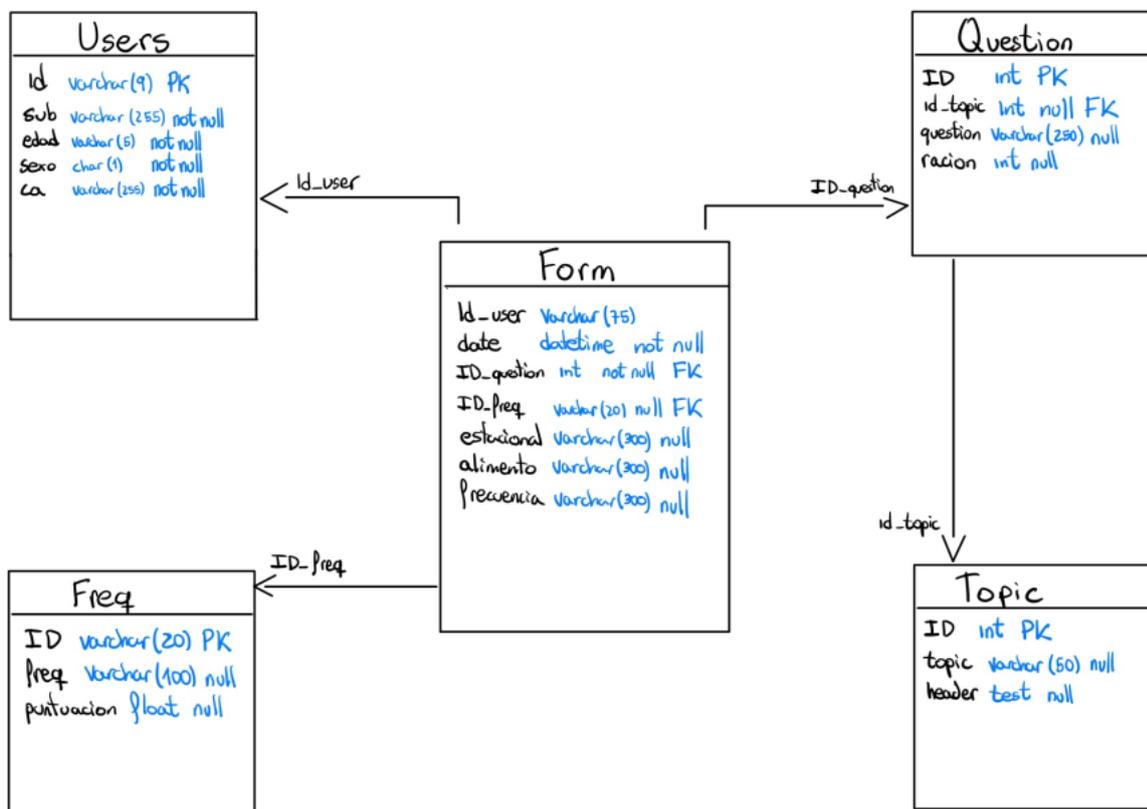


Figure 2.4: Diagrama base de datos

Diferenciar entre usuarios y brindar una experiencia personalizada.

La interfaz, como se detalla en la sección §2.2.2, se presenta de manera clara y fácil de entender. Además de su aspecto físico, se han incorporado funcionalidades para mejorar la experiencia del usuario. Por un lado, se brindan retroalimentaciones visuales cuando los usuarios interactúan con ciertos botones, los cuales cambian de color. También se muestra un mensaje de alerta cuando falta responder alguna pregunta (Figura §2.5). Estos elementos no solo facilitan la utilización de la herramienta, sino que también mejoran la experiencia global del usuario.

En cuanto a proporcionar una experiencia personalizada, se ha utilizado un sistema de autenticación de usuarios del IFCA basado en un sistema *Single Sign-On (SSO)*, seguido de su registro en la base de datos detallada en la sección anterior §2.2.2. La combinación de *SSO* y la base de datos permite almacenar las respuestas de cada usuario, además de incorporar un sistema de registro y inicio de sesión en la web.

igial ALIMENTA

pablo Izquierdo gonzalez

Inicio Perfil Usuario **Cuestionario** Informe

CUIDADO!! Quedan preguntas sin responder.
Tenga en cuenta que hay que marcar una respuesta en la columna 'ESTACIONALIDAD'.

CUESTIONARIO DE FRECUENCIA DE CONSUMO DE ALIMENTOS

I II III IV V VI VII VIII IX X

I-LÁCTEOS	CONSUMO MEDIO DURANTE EL AÑO PASADO									ESTACIONALIDAD
	Nunca o casi nunca	AL MES	A LA SEMANA			AL DIA				
			1-3	1	2-4	5-6	1	2-3		
1. Leche entera (1 taza, 200 cc)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
2. Leche semidesnatada (1 taza, 200 cc)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
3. Leche desnatada (1 taza, 200 cc)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
4. Leche condensada (1 cucharada)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
5. Nata o crema de leche (1/2 taza)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
6. Batidos de leche (1 vaso, 200 cc)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
7. Yogurt entero (1 unidad, 125 g)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
8. Yogurt desnatado (1 unidad, 125 g)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
9. Petit suisse (1 unidad, 55 g)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
10. Requesón o cuajada (1/2 taza)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
11. Queso en porciones, cremoso o queso de untar (tipo casero o philadelphia) (1 porción o 25 g)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
12. Otros quesos: curados, semicurados (Manchego, Bola, Emmental...) (50 g)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
13. Queso blanco o fresco (Burgos, cabra...) (50 g)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
14. Natillas, flan, puding (comerciales o caseros) (1 unidad, 130 cc)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
15. Helados (1 tarrina o 1 cucurucho)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	...

¿Consumes estos alimentos sin lactosa?

Figure 2.5: Retroalimentación visual al usuario

Asimismo, se ha creado un perfil de usuario que requiere que el usuario complete cierta información personal la primera vez que inicia sesión para finalizar su registro (Figura §2.6). Una vez registrado, se le asigna un identificador único para facilitar su identificación en futuras interacciones.

digital ALIMENTA

pablo Izquierdo gonzalez

Inicio **Perfil Usuario** Cuestionario Informe

PATRÓN DE DIETA DIGITALIZADO

Una herramienta digital para el registro de los hábitos alimentarios de la población.
Proyecto financiado por el Ministerio de Ciencia e Innovación (PID2019-108851RB9 y Prueba de Concepto PDC2922-133861)

Por favor, rellene sus datos personales.

Identificador: 60185f05T

Edad: 18-30

Sexo: Hombre

Comunidad Autónoma: Cantabria

Guardar

Figure 2.6: perfilUsuario

Al contar con un registro de las respuestas y con el propósito de personalizar la experiencia de los usuarios, tanto el índice de los cuestionarios como el "índice" de círculos se adaptan a los usuarios, ofreciendo una visión más clara de aquellos cuestionarios que ya han sido respondidos (Figura §2.7). Además, se ha implementado un histórico de informes, el cual se explica en la sección §2.2.2.

CUESTIONARIO DE FRECUENCIA DE CONSUMO DE ALIMENTOS

The image shows a vertical list of ten food categories, each in a rounded rectangular button. The first three buttons (I-LÁCTEOS, II-HUEVOS, CARNES, PESCADOS, and III-VERDURAS Y HORTALIZAS) are highlighted in light green. The remaining seven buttons (IV-FRUTAS, V-LEGUMBRES Y CEREALES, VI-ACEITES Y GRASAS, VII-BOLLERÍA Y PASTELERÍA, VIII-MISCELÁNEA, IX-BEBIDAS, and X-SUPLEMENTACIÓN NUTRICIONAL) are white with a thin grey border. At the bottom is a red button labeled 'Report/Informe'.

I-LÁCTEOS
II-HUEVOS, CARNES, PESCADOS
III-VERDURAS Y HORTALIZAS
IV-FRUTAS
V-LEGUMBRES Y CEREALES
VI-ACEITES Y GRASAS
VII-BOLLERÍA Y PASTELERÍA
VIII-MISCELÁNEA
IX-BEBIDAS
X-SUPLEMENTACIÓN NUTRICIONAL
Report/Informe

Figure 2.7: Ejemplo experiencia usuario

Generar automáticamente un informe alimenticio para el usuario.

Con el fin de ofrecer a los usuarios un informe detallado sobre los excesos y deficiencias en sus dietas, se ha habilitado una ventana (Figura §2.8) donde los usuarios pueden descargar su informe una vez que hayan respondido al cuestionario.

Este informe se genera automáticamente utilizando las respuestas del usuario almacenadas en la base de datos. Con estas respuestas, se calculan puntuaciones para cada grupo de alimentos, siendo proporcionales a las porciones de alimentos ingeridas. Luego, se generan dinámicamente unos gráficos de barras para cada grupo de alimentos (Figura §2.9), que expresan la puntuación obtenida y si está dentro o fuera de los límites recomendados. El informe es autoexplicativo, indicando qué preguntas proporcionan la puntuación en cada grupo y qué tamaños de porción se consideran estándar.



Figure 2.8: Ventana Informe

III. VERDURAS Y HORTALIZAS

Para este apartado se han tenido en cuenta las preguntas 39-51 (ambas incluidas).

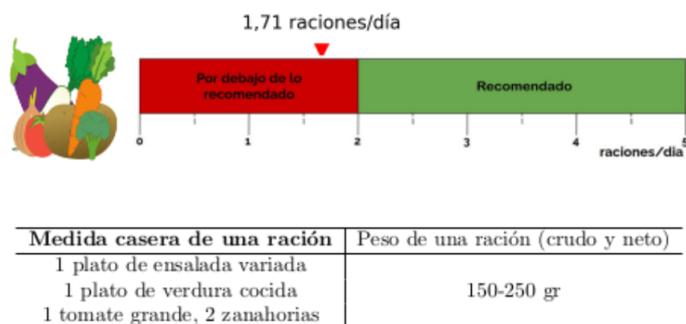


Figure 2.9: Ejemplo de gráfico auto-generado del informe

Mantener un historial de informes alimenticios.

Dado que se permite responder al cuestionario una vez a la semana, se vio necesario agregar la capacidad para que cada usuario pueda descargar cualquier cuestionario que haya completado. Esto mejora significativamente la herramienta, ya que permite regenerar los informes cuando sea necesario, evitando tener que descargarlos cada semana. Internamente, este cambio conllevó la incorporación de una variable temporal a varias funciones, además de realizar ciertos cálculos temporales sobre las respuestas almacenadas para diferenciar entre informes.

Finalmente, para la comodidad del usuario, se proporciona un menú desplegable donde este puede seleccionar la fecha deseada (Figura §2.10). Sin embargo, dado que es posible que un usuario inicie un cuestionario pero no lo finalice, algunas opciones pueden mostrar un mensaje de error notificando la falta de respuestas de ese informe.



Figure 2.10: Visualización del histórico de informes y notificación de error

Compatibilidad con dispositivos móviles

Siguiendo la premisa de desarrollar una herramienta fácil de usar y altamente accesible, este requisito busca garantizar la compatibilidad con dispositivos móviles. La principal consideración con estos dispositivos es la menor resolución de pantalla en comparación con un monitor estándar. Por lo tanto, es imperativo ajustar el tamaño de los elementos, como imágenes, botones y texto (Figura §2.11). Para lograr esta adaptabilidad, se han implementado "media queries", las cuales permiten aplicar estilos de CSS en función del tamaño de la pantalla del dispositivo, posibilitando que la web se ajuste de manera eficiente.



Figure 2.11: Visualización de la web en dispositivo móvil

Automatizar la extracción de datos a formato Excel.

Este requisito presenta una funcionalidad útil para los especialistas que harán uso de la herramienta, más que para los usuarios. Igualmente, es una funcionalidad de gran importancia, ya que se busca poder auto-generar un Excel que contenga de forma ordenada toda la información recogida en la base de datos (Figura §2.12). Además en este Excel, se realizan automáticamente los cálculos de los gramos/día de cada alimento, para su posterior uso por especialistas de nutrición.

Anteriormente, el cuestionario se aplicaba una vez y, posteriormente, transcurría un extenso período antes de realizarlo nuevamente. No obstante, la digitalización de este proceso permite una repetición más sencilla y sin necesidad de presencia física. Esta ventaja es significativa, ya que, al llevar a cabo el cuestionario con una frecuencia regular, como cada dos semanas, por ejemplo, el registro de todas las respuestas posi-

	A	B	C	D	E	F	G	H	I	J	K
1			I-LÁCTEOS								
2			1. Leche entera (1 taza, 200 cc)	2. Leche semidesnatada (1 taza, 200 cc)	3. Leche desnatada (1 taza, 200 cc)	4. Leche condensada (1 cucharada)	5. Nata o crema de leche (1/2 taza)	6. Batidos de leche (1 vaso, 200 cc)	7. Yogurt entero (1 unidad, 125 g)	8. Yogurt desnatado (1 unidad, 125 g)	9. Petit suisse (1 unidad, 55 g)
3		Ración (g)	200	200	200	15	100	200	125	125	55
4											
5	2023-11-13	Nº	1	6	1	1	1	1	1	2	1
6		g/día	0	200	0	0	0	0	0	8,75	0
7	2023-11-08	Nº	4	4	1	1	1	1	1	4	1
8		g/día	86	86	0	0	0	0	0	53,75	0
9											
10											
11											
12											
13											
14											
15											
16											
17											

Figure 2.12: Excel auto-generado con cálculos

bilita el análisis de la evolución en las dietas de los usuarios. Con este propósito, el archivo Excel dedica una hoja individual a cada usuario, organizada temporalmente, iniciando con los resultados más recientes y concluyendo con los más antiguos.

Incluir un cuestionario alimenticio de 24 horas.

Una vez implementados los requisitos mencionados anteriormente, la plataforma web ya está completamente funcional y cuenta con funcionalidades adicionales. Sin embargo, en los estudios alimenticios, también se emplean otros tipos de cuestionarios conocidos como "cuestionarios de 3 días" que registran todos los alimentos consumidos por los usuarios a lo largo de tres días. Estos cuestionarios en formato papel constan de tablas donde los usuarios detallan los alimentos y las cantidades ingeridas en cada comida (Desayuno, Almuerzo, Comida, Merienda y Cena)(Figura §2.13).

El objetivo es incorporar una nueva sección en la web destinada a este tipo de cuestionarios. La idea consiste en permitir a los usuarios cumplimentar el cuestionario diariamente. No obstante, los usuarios pueden consumir tantos alimentos distintos como deseen, lo que implica aumentar el número de campos de texto disponibles para el usuario. Esto se ha implementado mediante un botón que agrega filas a la tabla utilizando JavaScript.

CENA

Recuerde especificar :	ALIMENTOS	CANTIDAD	PREPARACIÓN O ALIÑOS	CANTIDAD ALIÑOS
Aperitivo: bebida, galletas saladas...	COCACOLA NORMAL			
Primer plato: verdura, cereales, patatas, legumbres...	BOBADILLO PEQUEÑO DE PAN HUECO BLANCO CON CHISTORRA & OLIVAS VERDES			
Segundo plato: carne, pescado, huevos...				
Acompañamiento: verdura, setas, patatas, arroz...				
Postre: fruta, yogur, pastel, helado...	DOS MANDARINAS Y 4 NIECES			
Pan: pan blanco, integral...				
Bebidas: agua, zumos de fruta, cerveza, vino, café, té...				

Figure 2.13: Tabla cena del cuestionario 3 días papel

Otro desafío que se observa en la imagen del cuestionario original §2.13 es la amplia variedad de alimentos que el usuario puede especificar. Con el fin de facilitar el manejo de los datos recopilados, se ha limitado la lista de alimentos disponibles a las preguntas del cuestionario de frecuencia, incluyendo algunos alimentos adicionales. Para simplificar el proceso de completar el cuestionario, se ha incorporado la funcionalidad de autocompletado. Esta característica permite a los usuarios seleccionar los alimentos de una lista predefinida. Sin embargo, en caso de que deseen introducir un alimento no presente en la lista, se ha añadido una tabla denominada "Otros" para incluir estos (Figura §2.14).

Porfavor, seleccione una fecha

02/01/2024 

<p>Desayuno</p> <table border="0" style="width: 100%;"> <thead> <tr> <th style="text-align: left;">Alimento</th> <th style="text-align: right;">Raciones</th> </tr> </thead> <tbody> <tr> <td><input type="text" value="Café (1 taza, 50 cc)"/></td> <td style="text-align: right;">1 </td> </tr> <tr> <td><input type="text" value="Pan blanco (3 rebanadas, 7"/></td> <td style="text-align: right;">0.5 </td> </tr> <tr> <td><input type="text" value="Mantequilla (1 porción indiv"/></td> <td style="text-align: right;">1 </td> </tr> </tbody> </table> <p style="text-align: center;"><input type="button" value="Añadir alimento"/></p>	Alimento	Raciones	<input type="text" value="Café (1 taza, 50 cc)"/>	1 	<input type="text" value="Pan blanco (3 rebanadas, 7"/>	0.5 	<input type="text" value="Mantequilla (1 porción indiv"/>	1 	<p>Merienda</p> <table border="0" style="width: 100%;"> <thead> <tr> <th style="text-align: left;">Alimento</th> <th style="text-align: right;">Raciones</th> </tr> </thead> <tbody> <tr> <td><input type="text"/></td> <td style="text-align: right;">0 </td> </tr> </tbody> </table> <p style="text-align: center;"><input type="button" value="Añadir alimento"/></p>	Alimento	Raciones	<input type="text"/>	0 
Alimento	Raciones												
<input type="text" value="Café (1 taza, 50 cc)"/>	1 												
<input type="text" value="Pan blanco (3 rebanadas, 7"/>	0.5 												
<input type="text" value="Mantequilla (1 porción indiv"/>	1 												
Alimento	Raciones												
<input type="text"/>	0 												
<p>Almuerzo</p> <table border="0" style="width: 100%;"> <thead> <tr> <th style="text-align: left;">Alimento</th> <th style="text-align: right;">Raciones</th> </tr> </thead> <tbody> <tr> <td><input type="text"/></td> <td style="text-align: right;">0 </td> </tr> </tbody> </table> <p style="text-align: center;"><input type="button" value="Añadir alimento"/></p>	Alimento	Raciones	<input type="text"/>	0 	<p>Cena</p> <table border="0" style="width: 100%;"> <thead> <tr> <th style="text-align: left;">Alimento</th> <th style="text-align: right;">Raciones</th> </tr> </thead> <tbody> <tr> <td><input type="text"/></td> <td style="text-align: right;">0 </td> </tr> </tbody> </table> <p style="text-align: center;"><input type="button" value="Añadir alimento"/></p>	Alimento	Raciones	<input type="text"/>	0 				
Alimento	Raciones												
<input type="text"/>	0 												
Alimento	Raciones												
<input type="text"/>	0 												
<p>Comida</p> <table border="0" style="width: 100%;"> <thead> <tr> <th style="text-align: left;">Alimento</th> <th style="text-align: right;">Raciones</th> </tr> </thead> <tbody> <tr> <td><input type="text"/></td> <td style="text-align: right;">0 </td> </tr> </tbody> </table> <p style="text-align: center;"><input type="button" value="Añadir alimento"/></p>	Alimento	Raciones	<input type="text"/>	0 	<p>Otros</p> <table border="0" style="width: 100%;"> <thead> <tr> <th style="text-align: left;">Alimento</th> <th style="text-align: right;">Raciones</th> </tr> </thead> <tbody> <tr> <td><input type="text"/></td> <td style="text-align: right;">0 </td> </tr> </tbody> </table> <p style="text-align: center;"><input type="button" value="Añadir alimento"/></p>	Alimento	Raciones	<input type="text"/>	0 				
Alimento	Raciones												
<input type="text"/>	0 												
Alimento	Raciones												
<input type="text"/>	0 												

Figure 2.14: Cuerpo de la venta web del cuestionario de 24 horas

Requisitos no funcionales.

En cuanto a la garantía de una disponibilidad del 80% del servicio web, actualmente, la plataforma está alojada en los servidores del IFCA, los cuales cuentan con protocolos específicos para mantener su operatividad. Además, se ha preparado el servicio para realizar un arranque automático en caso de que el servidor se apague. A largo plazo, se está considerando alguna empresa que mantenga la disponibilidad de la web en un futuro.

Para preservar los datos recopilados, el CPD del IFCA cuenta con protocolos de seguridad establecidos. También se ha programado un servicio para realizar copias de

seguridad de la base de datos y se ha implementado una tecnología llamada *SQLReplication*. Esta técnica consiste en clonar la base de datos en una máquina completamente independiente, donde todos los cambios realizados son propagados en esta segunda base de datos, proporcionando así un nivel de seguridad adicional.

Como último requisito no funcional, se busca reducir el tiempo de respuesta de la web a 3 segundos. Este valor se acordó como razonable para el tiempo de respuesta de la plataforma. Para lograr este objetivo, se ha utilizado "PageSpeed Insights" [5], una herramienta de Google que realiza pruebas de rendimiento de la web. Esta herramienta proporciona métricas, como el tiempo de respuesta, y ofrece consejos para mejorar estas métricas.

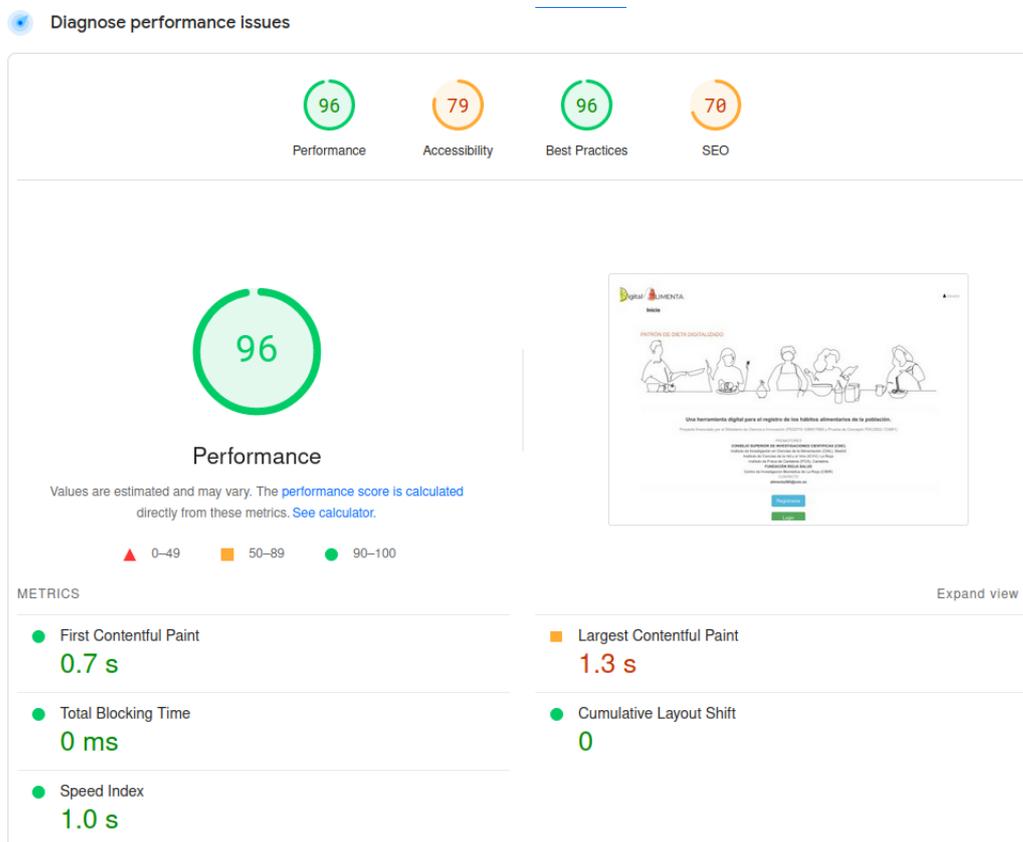


Figure 2.15: Test de respuesta digitalalimenta.csic.es en ordenador

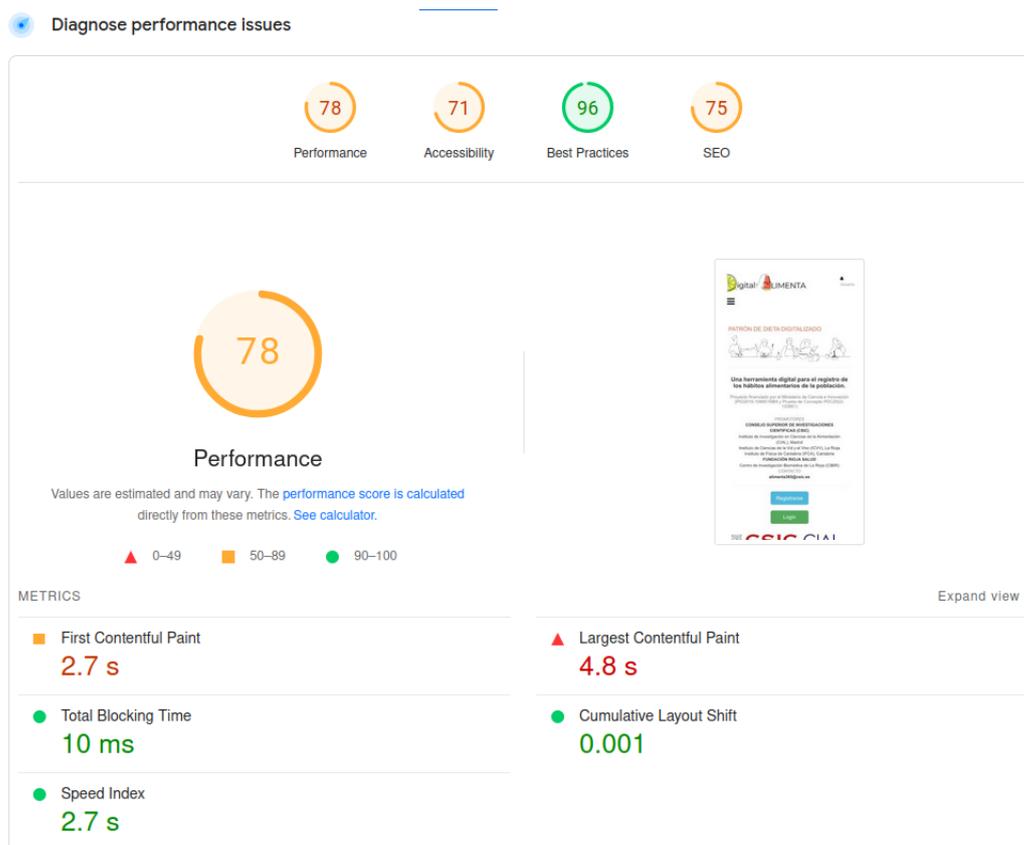


Figure 2.16: Test de respuesta digitalalimenta.csic.es en dispositivo móvil

Se puede notar que el tiempo de respuesta en dispositivos de escritorio es bastante bajo, alrededor de 1 segundo, mientras que en dispositivos móviles se sitúa en torno a los 3 segundos.

2.3 DATASET DE FRUTAS

En la sección anterior §2.2, se detalló el funcionamiento completo de la página web. Ahora, para la creación de una herramienta de *deep learning* que proporcione, a través de una imagen, el peso preciso de ciertas frutas, se requiere una amplia base de datos que contenga imágenes de frutas de laboratorio con diversas características. Estas imágenes se utilizarán para entrenar la red neuronal, y una vez obtenido un modelo satisfactorio, se empleará la herramienta con imágenes proporcionadas por los usuarios.

Este dataset de laboratorio se ha construido utilizando 51,840 imágenes de laboratorio recopiladas por los distintos centros involucrados en el proyecto, con el objetivo de disponer de un conjunto de datos extenso para el entrenamiento de la inteligencia

artificial.

Aunque este trabajo de fin de máster se centra específicamente en la creación de una herramienta para calcular el peso de las manzanas, el proyecto tiene como meta implementar herramientas similares para otras tres frutas de consumo común en España: peras, naranjas y plátanos. Las imágenes del conjunto de datos abarcan distintos tamaños, considerando tres calibres para manzanas, peras y naranjas (grande, mediano y pequeño) y dos para plátanos (grande y pequeño). Con el objetivo de obtener una amplia variedad de fotografías, se han utilizado 20 piezas de fruta por cada calibre y 30 piezas para plátanos, manteniendo el mismo número de imágenes por pieza. En resumen, se cuenta con 60 imágenes de cada tipo de fruta por centro, y cada centro proporciona una variedad específica de frutas, en el caso de las manzanas estas variedades son fuji, golden y granny smith.

2.3.1 Parámetros de la fotografía

A la hora de tomar las imágenes, se intenta ser lo más general posible intentando reflejar la variabilidad que existirá por parte de los voluntarios. Para lograrlo, se establecen diversos escenarios teniendo en cuenta factores como la iluminación, la posición de la fruta, la distancia a la fruta, entre otros.

Las imágenes presentan la fruta colocada en posición vertical en el centro, con orientación aleatoria y una moneda de 1€ como referencia en el extremo superior derecho. Se tomaron fotos combinando cada uno de los siguientes escenarios:

- **Luz:** Dada la variabilidad en la iluminación, las imágenes se capturaron en dos condiciones distintas: en el interior con un fondo blanco y sin flash, y en el exterior sin un fondo definido.
- **Plano:** Considerando que los voluntarios pueden tomar las imágenes a diferentes distancias, se ha reducido este parámetro a tres distancias: alejado (50-70 cm), medio (20-30 cm) y cercano (10-15 cm).
- **Ángulo:** Además de la distancia, el ángulo de la imagen también influye. Se han tomado imágenes de perfil (central 0°), otras con un ángulo superior de aproximadamente 30° y, por último, verticalmente con un ángulo de 90°.
- **Superficie:** La superficie y la posición de las frutas también son elementos importantes. Se han definido cinco superficies diferentes: fruta sobre superficie blanca, sobre mantel, y fruta sobre plato de postre o sobre plato grande.

En resumen, se han obtenido 72 fotos por pieza (36 en el interior y 36 en el exterior) multiplicado por 60 piezas, lo que resulta en 4,320 imágenes por centro. Esto da un total de 12,960 imágenes por cada tipo de fruta (Figura §2.17).

En el proceso de curación de datos, una vez que las imágenes han sido capturadas, resulta necesario etiquetarlas mediante un código preestablecido. Este código posibilita la identificación inequívoca de la imagen y describe los diversos parámetros con los cuales se tomó la fotografía.

Tomando como ejemplo las imágenes de manzanas, la codificación de la etiqueta comprende los siguientes campos:

- **Centro:** (Se disponen de dos centros en La rioja y un en Madrid)
Rio (Rioja), Mad (Madrid)
- **Tipo de Fruta:**
M (Manzana)
- **Variedad:**
Fuji, Golden, Granny Smith
- **Peso** (Peso de la fruta con precisión de dos decimales)
- **Superficie:**
Ppb (Plato pequeño blanco), Pgb (Plato grande blanco), Spb (Superficie blanco), Spm (Superficie mantel),
- **Luz:**
ext (Exterior), int (Interior)
- **Plano:**
ce (Cercano), me (Medio), al (Alejado)
- **Ángulo:**
cen (Centrado), sup (Superior), ver (Vertical)

El conjunto de datos completo se guarda en Nextcloud [8], una herramienta de almacenamiento en la nube de código abierto, siguiendo una estructura de carpetas que organiza la información por categorías (Fruta -> Variedad -> Peso).



Figure 2.17: Manzana Fuji de ejemplo del dataset

2.3.2 Herramientas

Las imágenes fueron capturadas utilizando un teléfono móvil, debido a su fácil utilización y amplia disponibilidad en la vida cotidiana. El dispositivo utilizado presenta las siguientes especificaciones de cámara:

- Cámara principal de 32, 48 MP.
- Cámara ultra gran angular de 123° con 8 MP.
- Cámara de profundidad de 5 MP (modo "live focus" desactivado).

Estas características son típicas en dispositivos móviles de gama media/baja en la actualidad.

MODELO DE APRENDIZAJE PROFUNDO

3.1 IMPLEMENTACIÓN

Para la ejecución de este proyecto, nos basamos en el trabajo presentado en el artículo "WineGut_BrainUP"[3], el cual introduce una herramienta destinada a estimar el volumen de vino contenido en una copa mediante el análisis de imágenes. En dicho estudio, los autores emplean la técnica de *transfer learning*[14], que busca potenciar el aprendizaje de las redes neuronales transfiriendo el conocimiento previamente adquirido de modelos afines. En otras palabras, una vez que un modelo ha sido entrenado para un propósito específico, es posible aprovechar el conocimiento acumulado en las capas iniciales como punto de partida para modelos con objetivos diferentes pero relacionados.

Según lo expuesto en el artículo, se utiliza la red neuronal Xception [2] junto con imágenes de 528x528 píxeles y el optimizador Adam [9]. Se ajustan diversos parámetros de acuerdo con los requisitos del problema y la capacidad computacional disponible. Se carga un modelo base preentrenado de ImageNet, al final de este se le añaden capas de activación lineal para adaptar el modelo a la tarea de estimar el volumen de vino.

Tomando como referencia lo mencionado anteriormente, en este proyecto se ha implementado una red neuronal utilizando *transfer learning*, con el propósito de predecir el peso de manzanas. Sin embargo, la adaptación de una red neuronal a un propósito diferente conlleva una serie de pasos; por un lado, es esencial realizar un adecuado preprocesamiento de los datos y buscar parámetros óptimos para la red. Además, se debe aplicar alguna técnica que proporcione un rango de error del modelo; en este trabajo, se realizará *bootstrapping*. Estos procedimientos se detallan en los subapartados siguientes.

3.1.1 Tratamiento de los datos

En la sección §2.3, se detalla el conjunto de datos que consta de 12,960 imágenes creado específicamente para el entrenamiento de la red neuronal. Durante la fase de

entrenamiento, es imperativo dividir este conjunto de datos en conjuntos de entrenamiento (70%), prueba (20%) y validación (10%), garantizando que no se utilicen imágenes de la misma manzana en grupos distintos. La razón de esta precaución radica en evitar que la red aprenda el peso específico de cada manzana, limitándose a diferenciarlas en lugar de predecir el peso. Además, se requiere una distribución equitativa de todas las variedades de manzanas y demás características presentes en las imágenes, como la presencia de manteles, diferentes platos, fondos diversos y los pesos de las manzanas. Cualquier desequilibrio entre estos grupos podría introducir sesgos en los resultados, afectando la capacidad de predicción para ciertas características.

Para abordar este proceso, se ha desarrollado un Jupyter Notebook, accesible a través del repositorio de Github[7], este lleva a cabo la división de los grupos de manera estratificada. Esta estratificación balancea los grupos según el peso, y al disponer del mismo número de imágenes de cada manzana se mantienen balanceadas las demás características. Las tablas siguientes muestran la distribución de las imágenes en los diferentes conjuntos según cada característica.

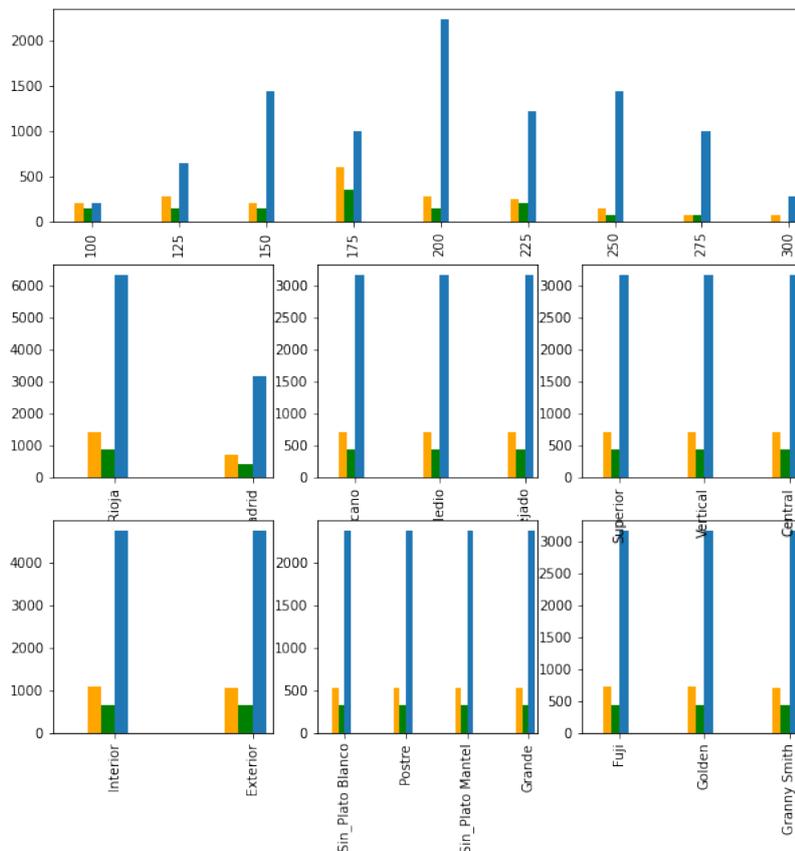


Figure 3.1: División del dataset en train, test y validación

3.1.2 Ajuste de parámetros

Con el objetivo de obtener un modelo de alta calidad, es esencial buscar los parámetros óptimos que maximicen el rendimiento en el problema que estamos abordando. Si bien existen técnicas automatizadas como *GridSearch*, que exploran rangos definidos de parámetros en busca de la combinación más efectiva, la complejidad del problema y la duración de las ejecuciones me llevaron a optar por un enfoque más selectivo. Dada la facilidad de experimentar con diferentes configuraciones de parámetros en el entrenamiento de la red neuronal y las diversas complejidades involucradas, decidí realizar la búsqueda de parámetros de forma manual.

Los parámetros con los que he experimentado han sido los siguientes:

- Tasa de aprendizaje (*Learning_rate*): 0.0001, 0.001, 0.01
- Tamaño del lote (*Batch_size*): 8 , 4

La elección de estos valores se basó en una lógica específica. Respecto al *learning_rate*, era crucial probar con diferentes órdenes de magnitud y seleccionar aquella que proporcionara el mejor rendimiento del modelo. En cuanto al *batch_size*, la limitada memoria del sistema impidió superar un valor de 8. Asimismo, un valor de *batch_size* inferior a 4 aumentaba el número de iteraciones en cada época y por ende el tiempo de ejecución.

La mejor configuración obtenida en estas experimentaciones se logró con un *learning_rate* de 0.001 y un *batch_size* de 4, como se muestra en la figura §3.2:

No obstante, los resultados revelaron un problema significativo de sobreajuste (*overfitting*). En un intento por mitigarlo, ajusté el parámetro de regularización L2. Esta técnica introduce una penalización adicional a la función de coste. Este término de penalización consiste en la suma de los cuadrados de los pesos, y es controlada por un hiperparámetro de regularización L2. Al incrementar este parámetro de 0.0001 a 0.0005, aumente la penalización lo que provocó cierta mejora, pero el problema de sobreajuste persistió.

Total training time: 1 day, 9:46:37

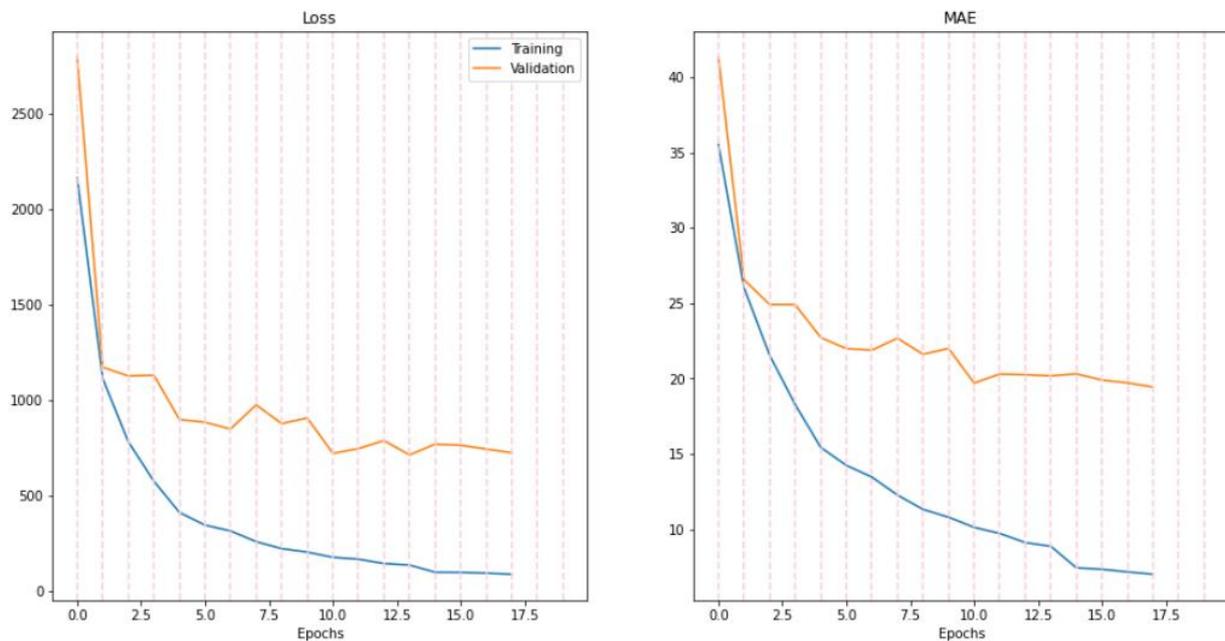


Figure 3.2: Gráficas LOSS y MAE con parámetros óptimos

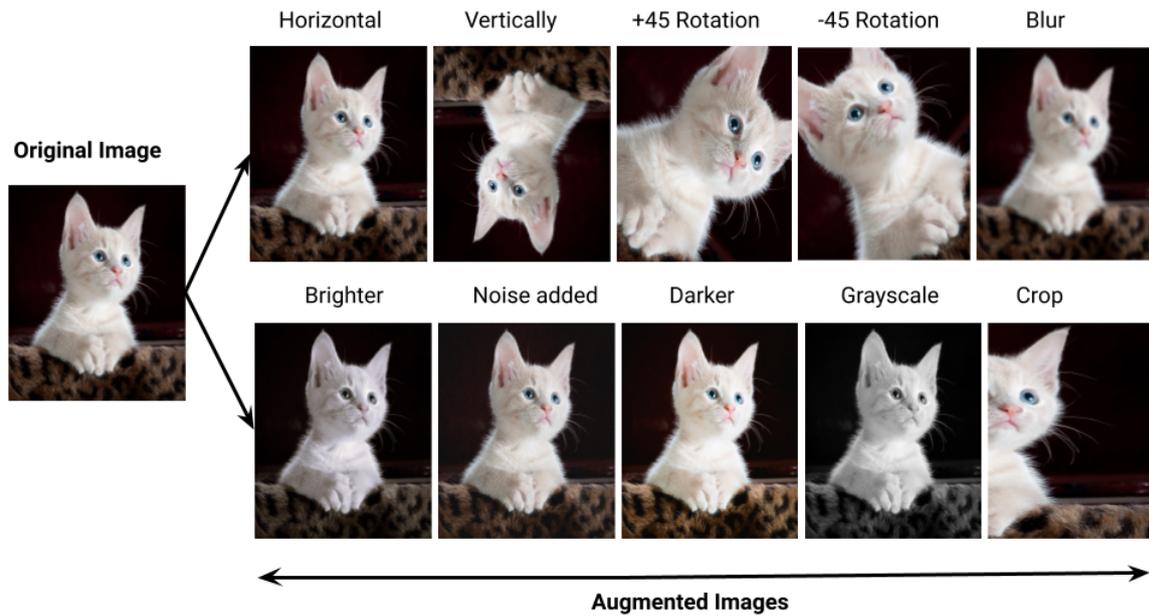
3.1.3 Reducción Overfitting

Cuando se enfrenta un problema de sobreajuste (*overfitting*) en el aprendizaje automático, no existe una solución única; más bien, cada problema puede abordarse mediante la implementación de diversas técnicas. En el contexto de este trabajo de fin de máster, se han empleado tres técnicas con el fin de mitigar el sobreajuste.

DATA-AUGMENTATION

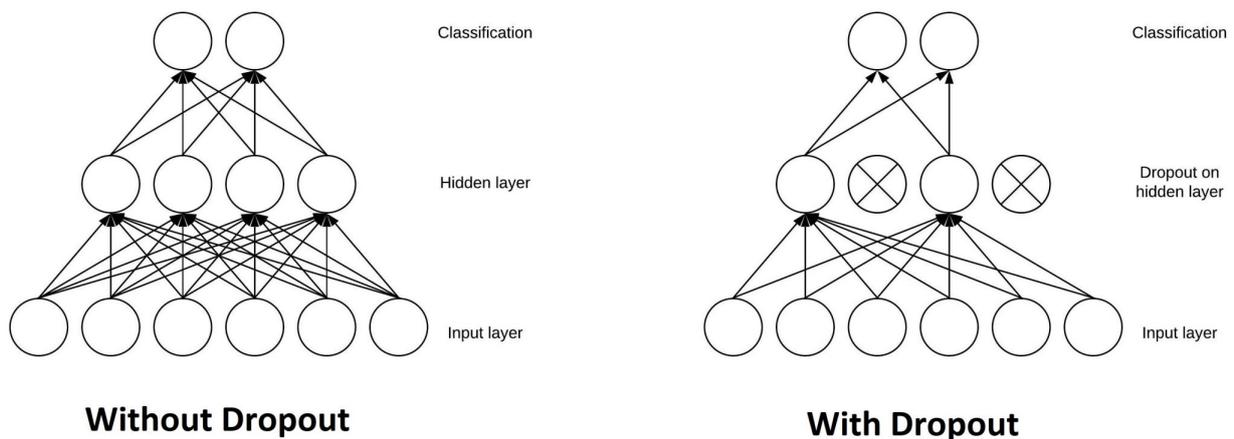
La técnica de *Data-Augmentation* en el aprendizaje automático se puede emplear con el propósito de mitigar el sobreajuste. Esta estrategia busca introducir variaciones digitales en las imágenes mediante diversos filtros, tales como rotaciones, zoom, cortes, ajustes de saturación de píxeles, aplicación de ruido, y desenfoco. Su objetivo es promover la generalización del aprendizaje, permitiendo que la red obtenga buenos resultados incluso con imágenes que no ha visto previamente.

En los resultados presentados en la sección anterior §3.1.2, ya se había aplicado esta técnica tanto en los datos de entrenamiento como en los de validación. No obstante, en aras de reducir el overfitting, se aumentó el porcentaje de imágenes afectadas por estos filtros para los resultados finales.

Figure 3.3: Ejemplo visual *Data-Augmentation* [12]

CAPAS DROPOUT

Otra estrategia para contrarrestar el sobreajuste consiste en la incorporación de capas de dropout al modelo. Esta técnica se fundamenta en la noción de que el sobreajuste se debe a una complejidad excesiva en la red neuronal, que puede aprender las imágenes de entrenamiento de memoria. Por lo tanto, las capas de dropout permiten "apagar" de manera aleatoria ciertas neuronas en la red neuronal, lo que reduce su complejidad y la hace menos propensa al sobreajuste.

Figure 3.4: Ejemplo visual *Dropout*

No obstante, debido al uso de transfer learning, solo es factible incorporar capas de dropout en la última capa de 1024 neuronas de la red. Esto limita las opciones de experimentación. Finalmente la estructura final seleccionada fue la siguiente:

- Dropout(0.25) -> 1024 Relu

Esta estructura, aunque mostró una mejora, aún no constituye un avance sustancial. Como se puede observar en la Gráfica §3.5.

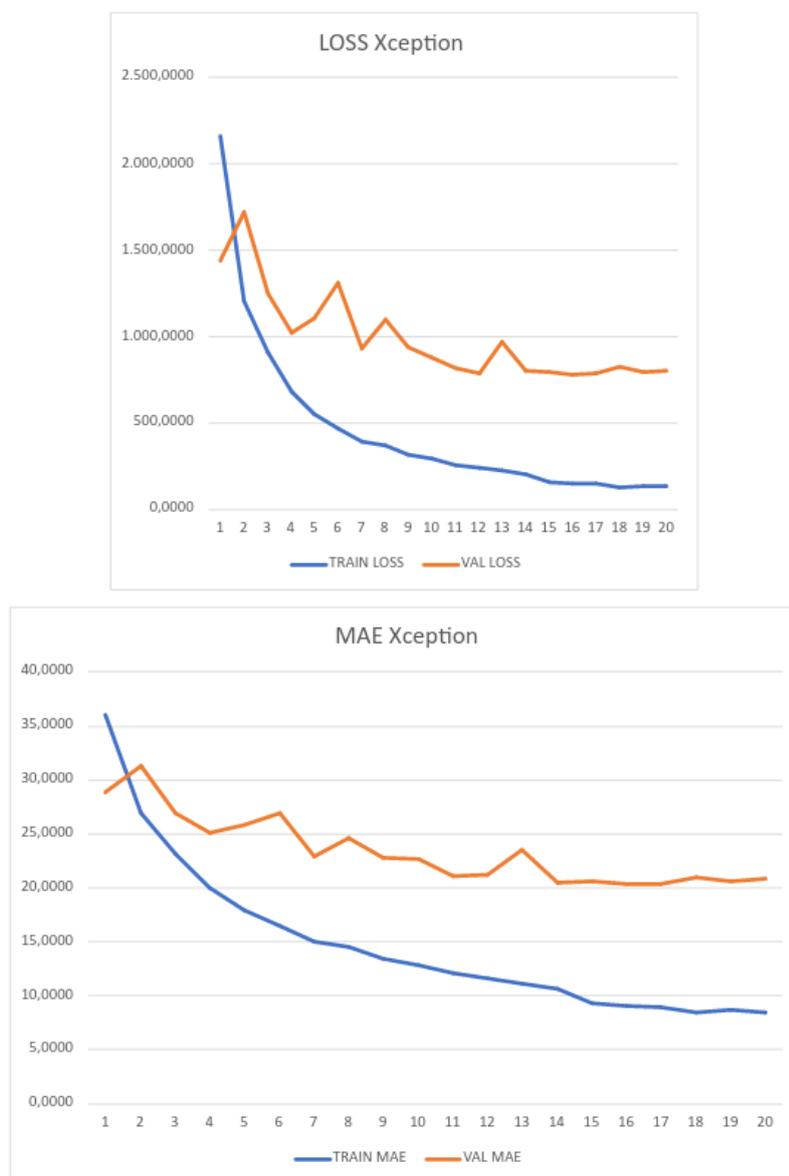


Figure 3.5: Resultados modelo Xception con Dropout

TRANSFER LEARNING

Como ya se ha explicado anteriormente §3.1, el transfer learning facilita el entrenamiento de nuevos modelos reutilizando lo aprendido en otras redes neuronales. Sin embargo, a la vista del problema de overfitting y que buscamos reducir la complejidad de la red, una opción es realizar transfer learning de un modelo que sea menos complejo o que se adapte mejor al problema que nos atañe.

Con esta idea en mente, realicé varias pruebas utilizando los modelos MobileNet, VGG16 y VGG19. Durante el proceso, noté una considerable reducción del sobreajuste en algunas pruebas. Por lo tanto, decidí reducir la influencia de la capa de dropout a un valor de 0.1 para observar si esto afectaba los resultados. Sin embargo, este cambio no provocó un aumento del sobreajuste, por lo que opté por mantener la influencia de la capa de dropout en 0.1. Los resultados obtenidos fueron los siguientes:

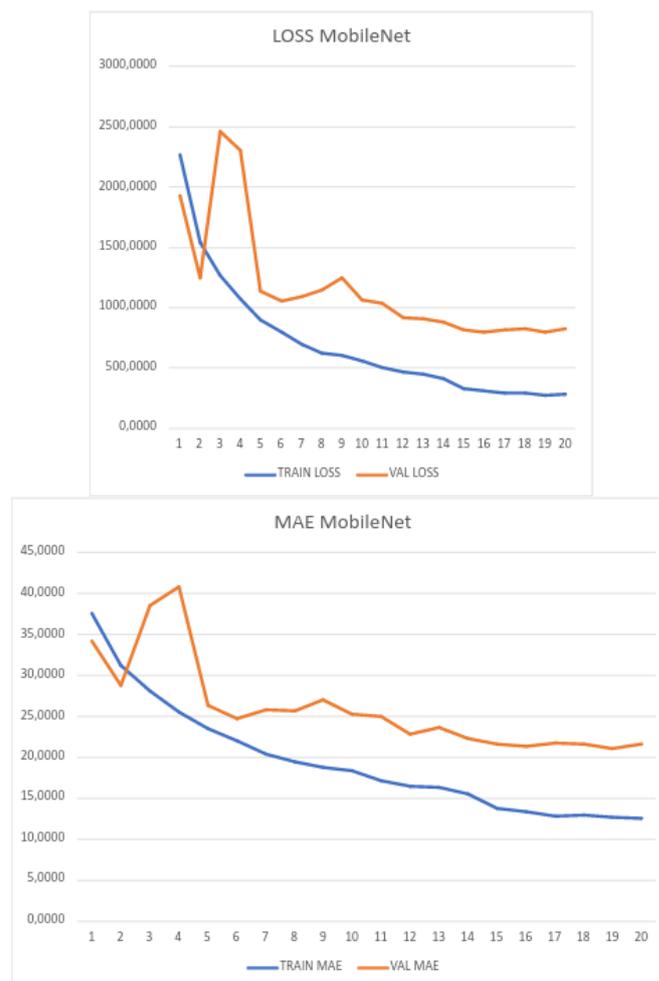


Figure 3.6: Resultados modelo MobileNet con Dropout

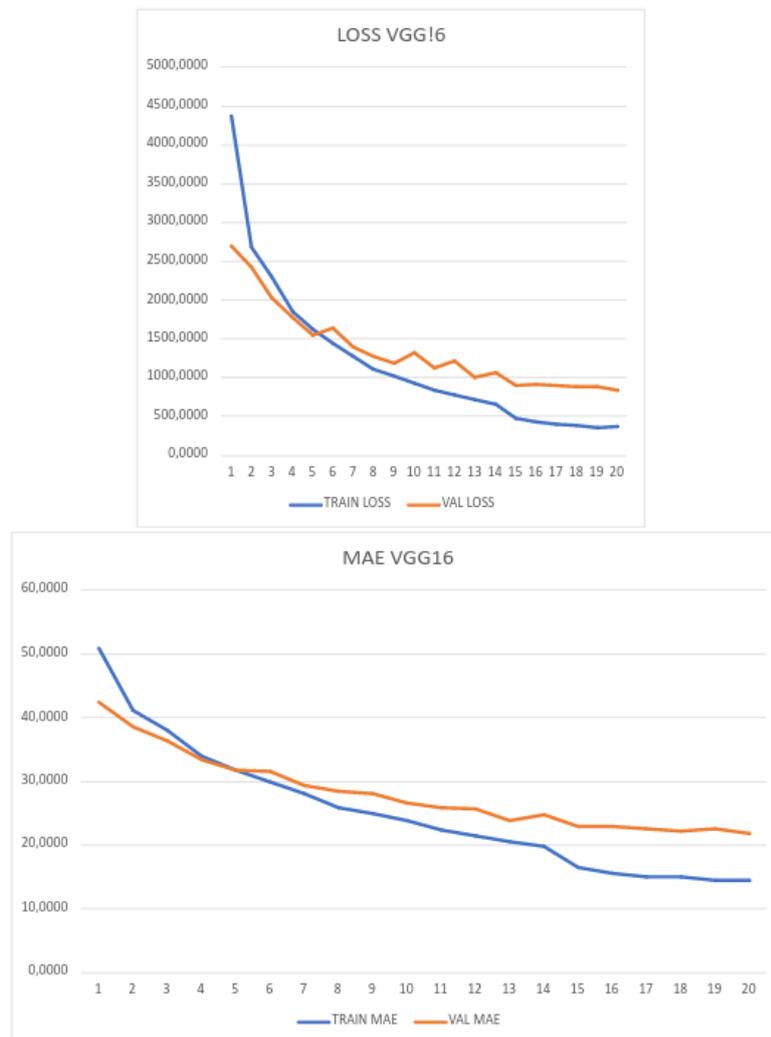


Figure 3.7: Resultados modelo VGG16 con Dropout

Realizando *transfer learning* desde MobileNet resultó en un sobreajuste aún menor. Sin embargo, los mejores resultados de *Mean Absolute Error (MAE)* en las imágenes de prueba, se obtuvieron con VGG16 y VGG19 valores de 20.7 gramos y 21.1 gramos respectivamente. Ambos resultados son comparables, pero al analizar las gráficas §3.7 y §3.8, se observa que el modelo VGG19 presenta una diferencia menor en el MAE (un menor sobreajuste) entre los datos de entrenamiento y validación.

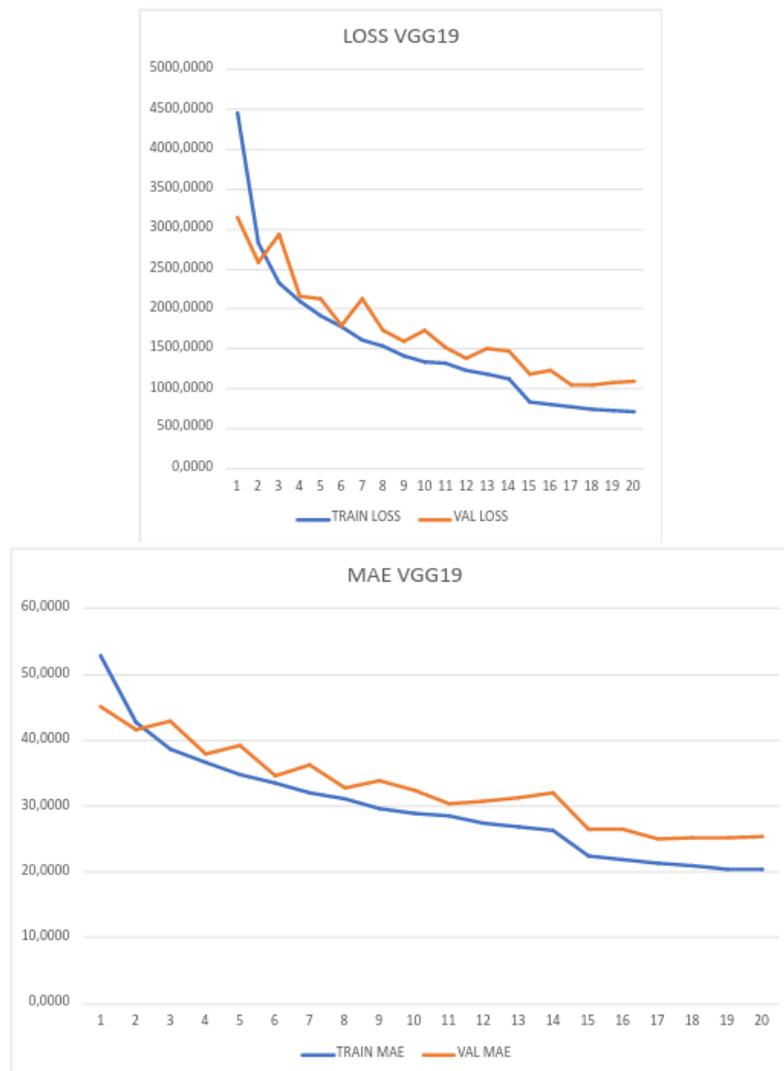


Figure 3.8: Resultados modelo VGG19 con Dropout

3.1.4 Bootstrapping

Después de completar todo el proceso de tratamiento de datos, ajuste de parámetros y reducción del sobreajuste, como se mencionó en los apartados anteriores, es crucial realizar una ejecución "final" para generar nuestro modelo. Sin embargo, con el fin de asegurar la fiabilidad del modelo y confirmar que presenta un error aceptable para el problema en cuestión, es necesario realizar ciertas pruebas. La más comúnmente utilizada es la validación cruzada, que implica generar varios modelos con conjuntos diferentes de datos de *train* y *test*, permitiendo así obtener un error promedio de la red neuronal. Lamentablemente, debido a limitaciones de tiempo, no fue posible llevar a cabo esta técnica. Por lo tanto, con el objetivo de proporcionar métricas confiables para

garantizar la fiabilidad del modelo obtenido, se optó por realizar *bootstrapping*.

El método de *bootstrap* es una técnica estadística que se basa en la simulación mediante remuestreo para estimar desviaciones estándar, intervalos de confianza, e incluso para contrastar hipótesis. En el contexto de este trabajo de fin de máster, este método se aplica mediante la generación de muestras del conjunto de datos de *test*, permitiendo la repetición de datos. Es crucial mantener estas muestras balanceadas en relación con los diferentes pesos de las manzanas, ya que realizar un muestreo aleatorio introduciría un sesgo significativo. Posteriormente, se realiza la predicción para cada muestra y se calculan las métricas estadísticas pertinentes. De este modo, se obtiene una estimación robusta de la variabilidad estadística que proporciona el modelo obtenido.

Para abordar el problema específico, se crearon 100 muestras, cada una compuesta por 1000 imágenes, y se calcularon las siguientes métricas:

- Error medio absoluto (EMA):
Esta métrica permite cuantificar la precisión de una herramienta de predicción. Se calcula como la media de la diferencia entre los valores predichos y los valores reales.
- Error relativo:
Esta métrica se utiliza para cuantificar la exactitud de una predicción en relación con su valor real. Se calcula como la diferencia entre el valor medido y el valor real, dividida por el valor real.
- Intervalo de confianza:
Es un rango que estima dónde podría estar una cierta predicción aún desconocida, con cierto nivel de confianza, basándose en los datos ya obtenidos. Este intervalo proporciona una medida de la incertidumbre asociada con la predicción.

RESULTADOS OBTENIDOS

4.0.1 Modelo Final

Antes de presentar los resultados finales, es crucial introducir la red neuronal utilizada junto con los hiperparámetros empleados, tras realizar todas las pruebas mencionadas en la sección §3.

En primer lugar, para la construcción de la red neuronal se ha aplicado transfer learning utilizando el modelo VGG19, cuya arquitectura se muestra en la figura §4.1. Sin embargo, como se explicó previamente, las últimas capas se han adaptado para la predicción del peso de las manzanas, reemplazando las originales por las siguientes capas: Dropout(0.1) -> Fully Connected con 1024 neuronas y una función de activación ReLU -> Fully Connected con 1 neurona y una función de activación lineal.

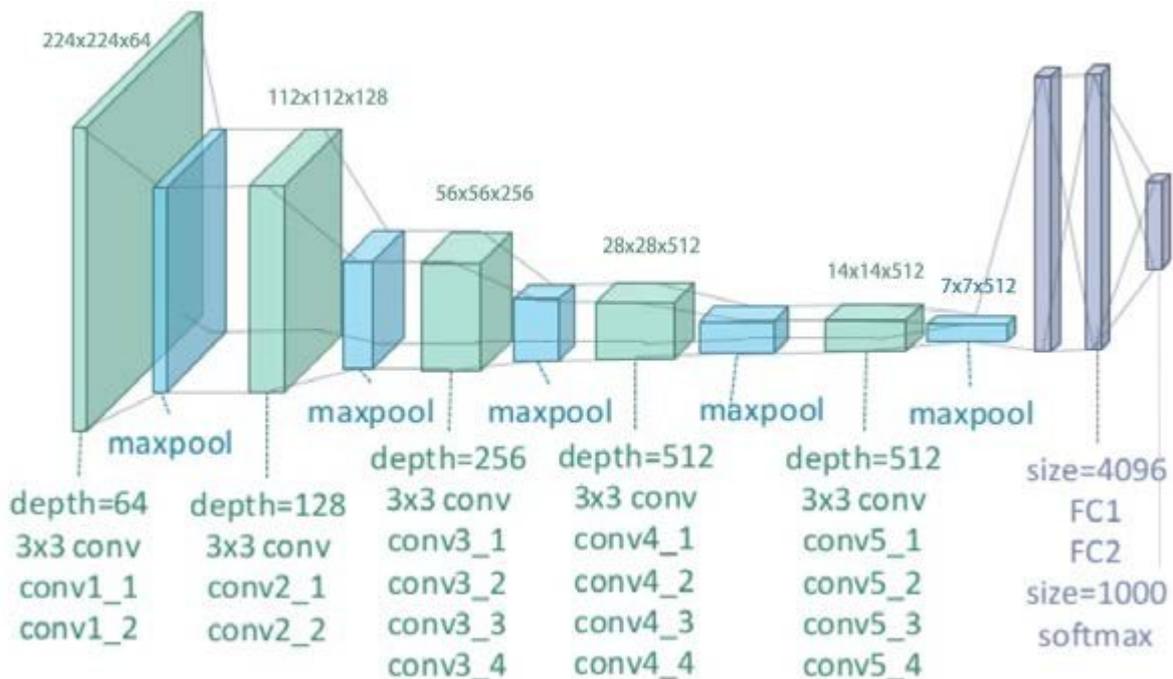


Figure 4.1: Arquitectura VGG19 (Fuente: researchgate.net [13])

Los parámetros finales empleados para obtener el modelo, que a su vez generó los resultados presentados posteriormente, se detallan en la tabla §4.1. En la sección §3.1.2, se discute el proceso mediante el cual se determinaron los hiperparámetros óptimos, utilizando un enfoque de prueba y error. Además, se incluyen en la tabla parámetros no mencionados anteriormente, pero comunes en el ámbito del aprendizaje profundo, por lo que es necesario su explicación.

- **BATCH_SIZE**: Representa el número de imágenes que contiene cada lote en los cuales se dividen los datos de entrenamiento. Durante el entrenamiento del modelo, se procesan estos lotes uno a la vez, y después de cada lote se actualizan los pesos del modelo. El tamaño del lote tiene un impacto significativo en la eficiencia computacional y en la gestión de la memoria.
- **CKPT_FREQ**: Determina la frecuencia con la que se crean copias de seguridad del modelo durante el entrenamiento. Con un valor de 0, se guarda el modelo una vez por época.
- **EPOCHS**: Especifica la cantidad de épocas que ejecutará el modelo durante el entrenamiento.
- **INITIAL_LR**: Indica el valor inicial del *learning rate*, el cual define la magnitud de los ajustes realizados a los pesos de la red neuronal.
- **L2_REG**: Controla la penalización realizada a través de la regularización L2. Explicada en la sección §3.1.2.
- **LR_SCHEDULE_MODE**: Puede tomar diferentes valores dependiendo del método deseado para ajustar el *learning rate*. En el caso del valor "Step", hace referencia a un decaimiento por factor fijo, es decir, reduce el *learning rate* multiplicándolo por un factor fijo después de cierto número de épocas.
- **LR_STEP_DECAY**: Es el factor fijo utilizado para ajustar el *learning rate*.
- **LR_STEP_SCHEDULE**: Determina en qué época se aplica el "lr_step_decay". Al tener un valor de 0.7 y 0.9 y conociendo que el número de épocas es 20, las épocas en las que se aplicará son la 14 y la 18 ($0.7 \cdot 20 = 14$, $0.9 \cdot 20 = 18$).
- **USE_EARLY_STOPPING**: Es un parámetro propio del código desarrollado que toma valores True/False y permite activar o desactivar la utilización de la técnica *early stopping*. Esta técnica permite detener el entrenamiento cuando se detecta que

el modelo comienza a empeorar o a sobreajustar, mediante un parámetro de paciencia. Durante la búsqueda de parámetros óptimos, pude observar algo de variación estadística que provocaba que el *early stopping* actuará. No obstante al deshabilitarlo, observe que 20 épocas era un parámetro aceptable para la obtención de resultados, debido a esto, se ha mantenido desactivado.

- **USE_MULTIPROCESSING:** Este parámetro, toma valores True/False, y determina la utilización de múltiples *workers*. Esto permite acelerar el entrenamiento.
- **USE_VALIDATION:** Determina la utilización de un grupo de imágenes como validación. Al ser *True*, es necesario disponer de un archivo "val.txt" con los path a las imágenes de validación.
- **MEAN_RGB:** Hace referencia a la media de los valores de los canales RGB de las imágenes de entrenamiento. Con ellos se normalizan los valores de los píxeles de las imágenes, centrando así los datos alrededor de cero, ya que las redes neuronales funcionan mejor con valores cercanos a cero.
- **STD_RGB:** Hace referencia a la desviación estándar de los valores de los canales RGB de las imágenes de entrenamiento. Para normalizar los píxeles de las imágenes, a cada píxel se le resta la media y se divide por la desviación estándar.
- **IMAGE_SIZE:** Especifica el tamaño en píxeles al cual se redimensiona cada imagen.
- **MODELNAME:** Es el nombre del modelo utilizado en el *transfer learning*.
- **OPTIMIZER:** Indica el nombre del optimizador utilizado. Adam (*Adaptive Moment Estimation*) es un optimizador muy utilizado en el aprendizaje profundo para ajustar los pesos de la red. En este caso, se utiliza "customAdam" debido a la necesidad de adaptar el optimizador Adam al método de decaimiento del *learning rate* por factor fijo.

Hiperparámetros Finales		
grupo	variable	valor
training	batch_size	4
training	ckpt_freq	0.0
training	epochs	20
training	initial_lr	0.001
training	l2_reg	0.0005
training	lr_schedule_mode	step
training	lr_step_decay	0.1
training	lr_step_schedule	[0.7, 0.9]
training	use_early_stopping	False
training	use_multiprocessing	True
training	use_validation	True
dataset	mean_RGB	[156.22266135452074, 151.02157182578048, 142.46801758553698]
dataset	std_RGB	[44.62250206124299, 46.46970319701125, 54.74363932234676]
model	image_size	528
model	modelname	VGG19
model	optimizer	customAdam

Table 4.1: Hiperparametros Finales

Además, la técnica de *Data-Augmentation* también cuenta con ciertos hiperparámetros propios, los cuales se presentan en la tabla §4.2. Estos parámetros difieren dependiendo de si el *data-augmentation* se aplica durante el entrenamiento o la validación. Generalmente, durante el entrenamiento, los filtros aplicados con esta técnica son más rigurosos para evitar el sobreajuste de la red. A continuación se explican estos parámetros:

- H_FLIP: Representa la probabilidad de realizar un volteo horizontal de 180°.
- V_FLIP: Indica la probabilidad de efectuar un volteo vertical de 180°.
- ROT: Se refiere a la probabilidad de aplicar una rotación sobre la imagen.
- ROT_LIM: Especifica el ángulo máximo permitido para la rotación de la imagen.
- STRETCH: Define la probabilidad de aplicar un estiramiento aleatorio a la imagen, aunque se establece en cero por defecto debido a que en algunos conjuntos de datos puede generar imágenes sin sentido.
- CROP: Determina la acción de tomar un recorte aleatorio de la imagen.
- ZOOM: Probabilidad de aplicar un zoom aleatorio sobre el recorte realizado.
- CROP=1, ZOOM=0.1: Con esta configuración, se realiza un recorte aleatorio con un tamaño variable entre el 100% de la imagen y el 90% de la misma.
- BLUR: Corresponde a la probabilidad de aplicar un difuminado aleatorio a la imagen.
- PIXEL_NOISE: Se refiere a la probabilidad de añadir ruido de píxeles aleatorio a la imagen.
- PIXEL_SAT: Determina la probabilidad de utilizar aleatoriamente el espacio de color HSV en la imagen, lo que varía el tono, saturación y valor de los colores de los píxeles.
- CUTOUT: Indica la probabilidad de realizar recortes aleatorios en la imagen.

Hiperparametros Data-Augmentation	
Modo Entrenamiento	
<i>variable</i>	<i>valor</i>
h_flip	0.5
v_flip	0.0
rot	0.5
rot_lim	45
stretch	0.0
crop	1.0
zoom	0.1
blur	0.3
pixel_noise	0.3
pixel_sat	0.3
cutout	0.1
Modo Validación	
<i>variable</i>	<i>valor</i>
h_flip	0.2
v_flip	0.0
rot	0.2
rot_lim	30
stretch	0.0
crop	0.1
zoom	0.0
blur	0.1
pixel_noise	0.1
pixel_sat	0.1
cutout	0.0

Table 4.2: Hiperparametros Data-Augmentation

4.0.2 Entorno de Ejecución

Para realizar el entrenamiento y la predicción del modelo, se ha empleado una herramienta llamada AI4EOSC [1], la cual ofrece una variedad de servicios destinados al desarrollo de modelos y aplicaciones de inteligencia artificial, aprendizaje automático (Machine learning) y aprendizaje profundo (Deep learning). Estos servicios están disponibles tanto para la comunidad investigadora como para empresas interesadas en utilizar estas tecnologías de vanguardia.

AI4EOSC facilita el despliegue de una imagen docker [4], utilizando en este caso la misma imagen utilizada en el proyecto "WineGut_BrainUP" [3]. Esta herramienta permite lanzar la imagen en máquinas con la capacidad de cómputo necesaria para la tarea en cuestión. En el contexto de este trabajo de fin de máster, se ha desplegado sobre máquinas con 4 CPUs a 8796 MHz, 8GB de RAM, 10GB de almacenamiento y una GPU Testla T4 con 15GB de memoria.

Una vez se dispone de un entorno de ejecución adecuado, se puede encontrar el código desarrollado en el repositorio de github [7].

4.0.3 Resultados Obtenidos

El modelo en cuestión se entrenó utilizando un conjunto reducido de imágenes para validación, lo que permite detectar posibles problemas de sobreajuste. A partir de los valores de pérdida (*loss*) y Error Absoluto Medio (*MAE*) registrados durante el proceso de entrenamiento, se generó la gráfica §4.2.

Lo más notable de esta gráfica §4.2 es que ambas curvas permanecen cercanas entre sí a lo largo de todo el entrenamiento, y en las últimas épocas se observa que la diferencia entre ambos modelos es muy pequeña, por lo que descartamos el sobreajuste.

Total training time: 8:42:24
 Difference of MAE: 0.7113418579101562

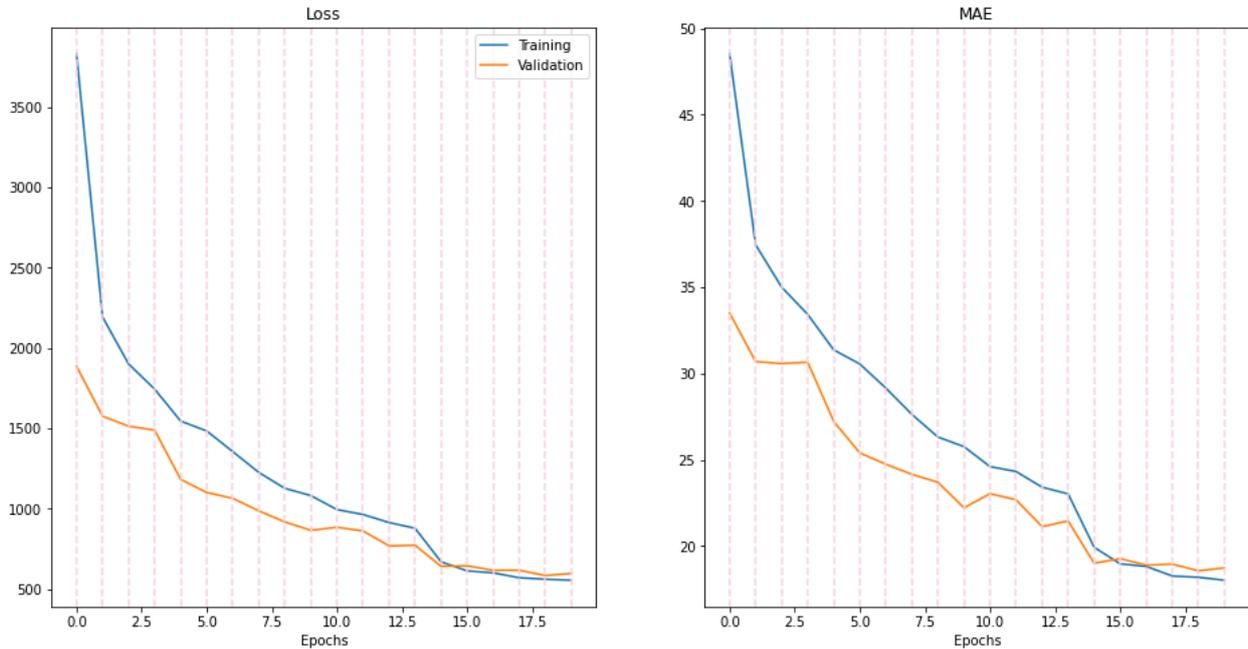


Figure 4.2: Gráficas LOSS y MAE del modelo final

A continuación, se presentan los resultados obtenidos en la evaluación del modelo. La tabla §4.3 resume las métricas clave, incluyendo el Error Absoluto Medio (*MAE*) y el Intervalo de Confianza del 95% de los datos. Los resultados resumen las estadísticas del método de *bootstrapping* utilizado en la evaluación.

Resultados Obtenidos	
MAE	95% IC
27.4	26.5, 28.3

Table 4.3: Resultados del bootstrap del modelo

Es importante destacar que el *MAE* mostrado es el promedio de las 100 muestras de *bootstrap*. No obstante, el error varía dependiendo del peso de la manzana. Esto se puede observar en la figura §4.3, donde se evidencia que cuando el peso de la manzana supera los 225 gramos, el peso predicho dista en mayor medida con el peso real.

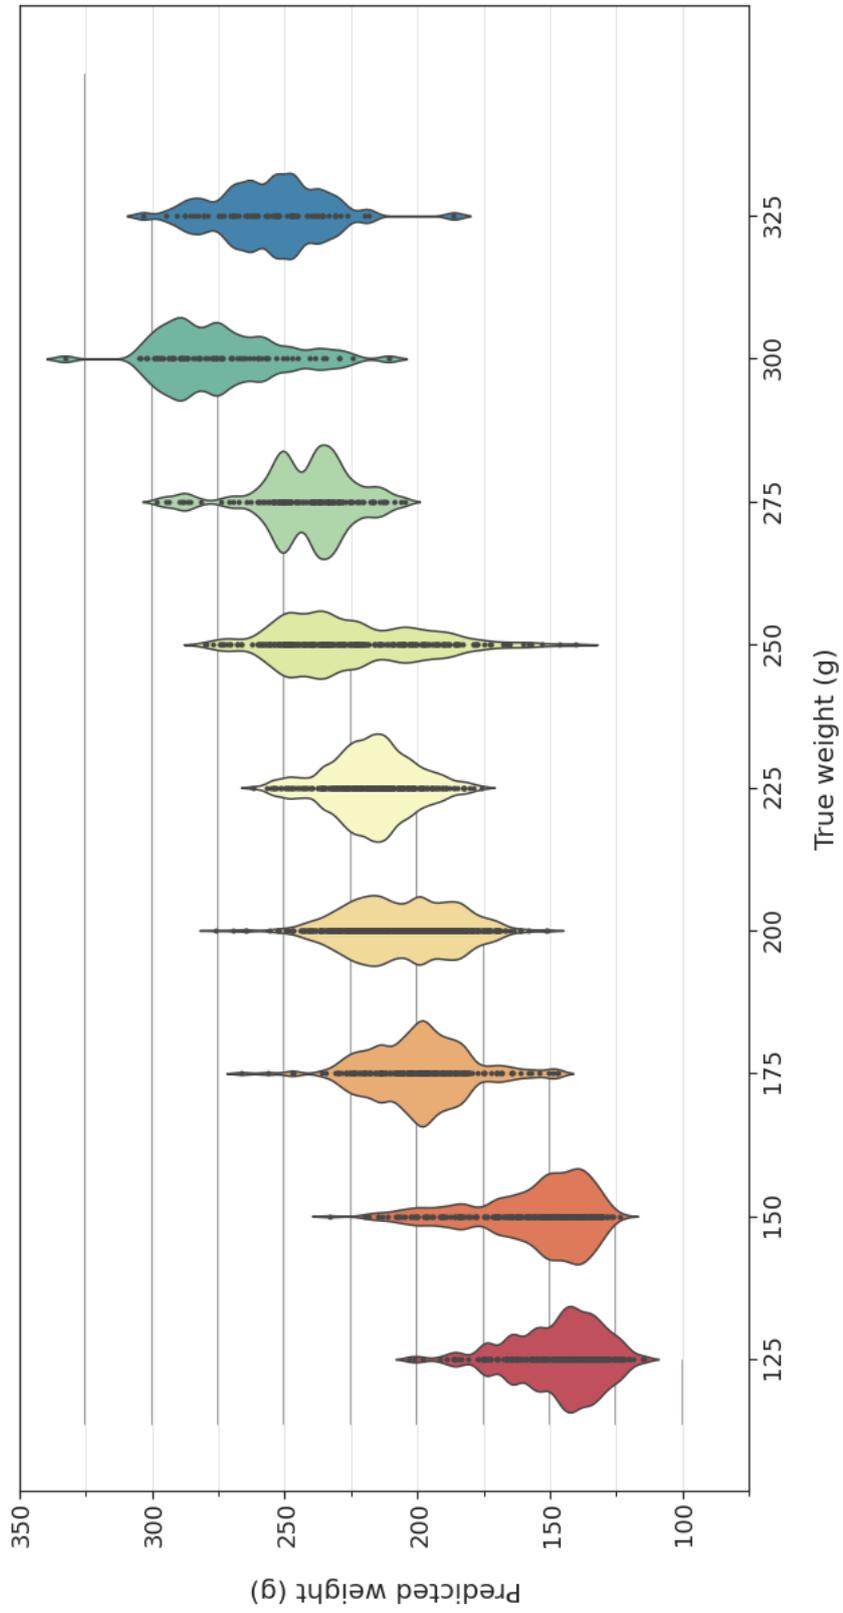


Figure 4.3: Representación predicciones imágenes test

CONCLUSIONES

5.1 OBJETIVOS CONSEGUIDOS

En resumen, varios de los objetivos propuestos al inicio de esta memoria han sido alcanzados con éxito. Se ha implementado una herramienta web que brinda consejos alimenticios a los usuarios y datos útiles a los expertos para la realización de estudios alimenticios.

Además, se ha desarrollado un modelo de aprendizaje profundo capaz de predecir el peso de las manzanas. Los problemas encontrados a la hora de obtener predicciones más precisas se atribuye a la naturaleza del problema, ya que la red neuronal se basa en imágenes bidimensionales desde un solo ángulo, sin disponer de imágenes en diferentes ángulos que proporcionarían una idea tridimensional. A pesar de esto, las predicciones ofrecidas son más precisas que simplemente establecer una ración estándar para las manzanas.

5.2 TRABAJOS FUTUROS

Como continuación de este trabajo de fin de máster, se planea realizar pruebas adicionales al modelo obtenido, aplicando técnicas de validación cruzada (*cross-validation*). Además, se tiene la intención de avanzar con los objetivos del proyecto DigitalAlimenta, desarrollando modelos para el resto de frutas como peras, naranjas y plátanos.

5.3 REFLEXIÓN PERSONAL

Como reflexión final de mi trabajo de fin de máster, considero que ha sido un logro personal significativo. No solo he tenido la oportunidad de adquirir conocimientos sobre nuevas tecnologías, sino también de aplicar todo lo aprendido durante el máster para abordar un problema complejo utilizando redes neuronales.

Este proyecto ha sido una prueba contundente de que el conocimiento adquirido durante el máster es invaluable. Me ha proporcionado las habilidades necesarias para resolver problemas que van más allá de la capacidad humana. Estoy convencido de que este aprendizaje será extremadamente útil en mi futuro profesional, permitiéndome enfrentar desafíos con confianza y obtener resultados exitosos.

BIBLIOGRAPHY

- [1] AI4EOSC. Ai4eosc webpage. URL <https://ai4eosc.eu/>.
- [2] F. Chollet. Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1251–1258, 2017.
- [3] M. Cobo, I. Heredia, F. Aguilar, L. Lloret Iglesias, D. García, B. Bartolomé, M. V. Moreno-Arribas, S. Yuste, P. Pérez-Matute, and M.-J. Motilva. Artificial intelligence to estimate wine volume from single-view images. *Heliyon*, 8(9):e10557, 2022. ISSN 2405-8440. doi: <https://doi.org/10.1016/j.heliyon.2022.e10557>. URL <https://www.sciencedirect.com/science/article/pii/S240584402201845X>.
- [4] DEEP-Hybrid-DataCloud. `deephdc/deep-oc-image-classification-tf`, 2022. URL <https://hub.docker.com/r/deephdc/deep-oc-image-classification-tf>.
- [5] Google. Pagespeed insights. URL <https://pagespeed.web.dev/>.
- [6] IBM. What is computer vision?, 2024. URL <https://www.ibm.com/topics/computer-vision>.
- [7] P. Izquierdo. `image-classification-tf`. <https://github.com/Pablo-Izquierdo/image-classification-tf>, 2023.
- [8] Karlitschek. Nextcloud. URL <https://nextcloud.com.es/>.
- [9] D. P. Kingma and J. Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- [10] W. W. ROYCE. Managing the development of large software systems: concepts and techniques. *En Proceedings of the 9th international conference on Software Engineering.*, pages 328–338, 1987. ISSN 2123-1234.
- [11] I. SOMMERVJLLE. *Ingeniería del software (7.ª ed.)*. Pearson, Madrid, Spain, 2005. ISBN 84-7829-074-5.

- [12] ubiai. What are data augmentation techniques : [2024 update], 2023. URL https://ubiai.tools/wp-content/uploads/2023/11/0_LNtz0G4cngapDH41.png.
- [13] C. K. Yang. Illustration of the network architecture of vgg-19 model, 2018. URL https://www.researchgate.net/figure/Illustration-of-the-network-architecture-of-VGG-19-model-conv-means-convolution-fig2_325137356.
- [14] F. Zhuang, Z. Qi, K. Duan, D. Xi, Y. Zhu, H. Zhu, H. Xiong, and Q. He. A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1):43–76, 2021. doi: 10.1109/JPROC.2020.3004555.