

Mejora de la salud a través del análisis de los hábitos alimenticios por medio de sistemas automáticos

Sergio Romero Tapiador

Máster Universitario en Investigación e Innovación en Inteligencia Computacional y Sistemas Interactivos



MÁSTERES
DE LA UAM
2021-2022

Escuela Politécnica Superior

UAM Universidad Autónoma
de Madrid

UNIVERSIDAD AUTÓNOMA DE MADRID

ESCUELA POLITÉCNICA SUPERIOR



Trabajo Fin de Máster

Mejora de la Salud a través del Análisis de los Hábitos Alimenticios por medio de Sistemas Automáticos

Máster Universitario en Investigación e Innovación en Inteligencia Computacional y Sistemas Interactivos

Autor: Sergio Romero Tapiador
Tutor: Rubén Tolosana Moranchel
Ponente: Rubén Vera Rodríguez

Febrero 2022

Mejora de la Salud a través del Análisis de los Hábitos Alimenticios por medio de Sistemas Automáticos

Autor: Sergio Romero Tapiador
Tutor: Rubén Tolosana Moranchel
Ponente: Rubén Vera Rodríguez



Biometrics and Data Pattern Analytics Lab
Departamento de Tecnología Electrónica y de las Comunicaciones

Febrero 2022

Resumen

En este Trabajo de Fin de Máster se implementa el primer entorno programable que permite crear bases de datos sintéticas a partir de perfiles que simulan diferentes hábitos de comportamiento alimentario. Para tal fin, se ha generado una base de datos de imágenes de alimentos que refleja los diferentes grupos alimentarios que existen y en segundo lugar, se han creado una serie de perfiles que repliquen distintos hábitos de comportamiento alimentario, incluyendo perfiles asociados a una alimentación sana e insana.

De esta manera, el conjunto de datos de alimentos se ha creado a partir de una selección de bases de datos de imágenes de alimentos que conforman el Estado del Arte. Para ello, estas bases de datos deben incluir una gran variedad de productos que se encuentren en los diferentes grupos alimentarios, con el objetivo de definir tantas categorías como grupos de alimentos se encuentren. Por otro lado, los perfiles se han generado en base a una serie de escenarios que cubren distintos hábitos de comportamiento alimenticio. En este caso, se ha tenido en cuenta las directrices marcadas por diferentes organizaciones de carácter nacional e internacional, las cuales proporcionan una serie de recomendaciones sobre la alimentación saludable.

Por ello, se ha desarrollado un entorno configurable que genera, de forma automática, dietas capaces de simular entornos reales a través de perfiles que se asemejen a los hábitos de comportamiento alimenticio y que estén formadas por las imágenes que se encuentran en la base de datos de alimentos y grupos alimentarios generada.

Posteriormente, se han analizado y evaluado las 2 bases de datos generadas utilizando técnicas de aprendizaje automático. Por último, se han extraído las conclusiones de este trabajo y se han propuesto líneas de investigación posibles para futuros trabajos.

Palabras Clave

Food Computing, Alimentación Saludable, Hábitos de Comportamiento Alimenticio, Bases de Datos de Alimentos, Bases de Datos Sintéticas, Clasificación de Alimentos, Entorno Programable.

Abstract

In this M.Sc. Thesis, a first programmable environment that generates synthetic databases from eating habits profiles is implemented. To that end, a food image database from different food groups has been created. Secondly, a series of profiles that replicate different eating behavior habits have been created, including those associated with healthy and unhealthy eating.

For that reason, some of the food image databases from State-of-the-Art have been selected to generate a new one. These databases must include a wide variety of products and different food groups. Therefore, the new database has as many categories as food groups. On the other hand, profiles that simulate different eating behavior habits according to the guidelines from national and international organizations have been followed in order to create them.

Moreover, a configurable environment that automatically generates diets has been developed. This environment is able to simulate real conditions using eating habits profiles and images found in the generated food image database.

Then, both food image and synthetic database have been analyzed and evaluated using machine learning techniques. Finally, some conclusions and possible future work lines are drawn.

Key words

Food Computing, Healthy Diet, Eating Behavior Habits, Food Image Database, Synthetic Database, Food Classification, Programmable Environment.

Agradecimientos

En primer lugar, me gustaría agradecer a Rubén Tolosana por toda su entrega hacia mí durante estos más de dos años. La manera en la que me ha enseñado todo lo que sé es única y sin él, ahora mismo no estaría escribiendo estas palabras. Agradecer toda su constancia y apoyo, así como su forma en la que me anima en todo momento. ¡Muchas gracias Rubén!

Agradecer a toda mi familia y amigos por el simple hecho de estar a mi lado, un apoyo fundamental que valoro enormemente. Desde mi madre, mi padre, mi hermana (y lo que viene), Irene y toda la familia asociada hasta mis amigos de toda la vida, los de la carrera y todos aquellos que no he nombrado implícitamente pero que han hecho un hueco para formar parte de su vida.

A todos ellos, porque sigan buscando la manera de ser felices, que es lo que realmente importa.

*Sergio Romero Tapiador
Febrero 2022*

Índice general

Índice de Figuras	IX
Índice de Tablas	X
1. Introducción	1
1.1. Motivación del Proyecto	1
1.2. Objetivos y Enfoque	2
1.3. Metodología y Plan de Trabajo	3
1.4. Organización de la Memoria	3
2. Estado del Arte	5
2.1. <i>Food Computing</i>	5
2.1.1. Reconocimiento de Alimentos	6
2.2. Clasificación de Alimentos	7
2.2.1. Bases de Datos	7
2.2.2. Clasificación de Alimentos	11
2.3. Hábitos Saludables y Dietas Personalizadas	14
2.3.1. Hábitos Saludables	14
2.3.2. Sistemas de Recomendación Personalizados	16
2.4. Conclusiones	18
3. Base de Datos de Alimentos y Grupos Alimentarios	19
3.1. Selección de Bases de Datos	19
3.1.1. <i>UECFood-256</i>	19
3.1.2. <i>Food-101</i>	20
3.1.3. <i>Food-11</i>	20
3.1.4. <i>FruitVeg-81</i>	20
3.1.5. <i>MAFood-121</i>	21
3.1.6. <i>ISIA Food-500</i>	21
3.1.7. <i>VIPER-FoodNet</i>	21
3.2. Categorización	21

3.2.1. Clasificación por Categorías y Subcategorías	22
3.2.2. Otros Tipos de Clasificación	24
4. Hábitos de Comportamiento Alimenticio: Entorno Programable	31
4.1. Parametrización	31
4.1.1. Parámetros Asociados a las Características de la Dieta	32
4.1.2. Parámetros Asociados al Grupo de Alimentos	32
4.1.3. Parámetros Asociados al Grado de Ingesta	33
4.1.4. Parámetros Asociados al Pan y Bebidas	34
4.2. Creación de los Perfiles	34
4.2.1. Asignación de Valores	36
4.3. Creación de la Base de Datos Sintética	38
5. Experimentos: Base de Datos de Alimentos y Grupos Alimentarios	41
5.1. Sistema Propuesto	41
5.2. Protocolo Experimental	42
5.3. Resultados Experimentales	43
5.3.1. Evaluación Frente a Bases de Datos del Estado del Arte	43
5.3.2. Evaluación Frente a la Base de Datos de Alimentos y Grupos Alimentarios Generada	44
6. Experimentos: Base de Datos de Hábitos de Comportamiento Alimenticio	47
6.1. Análisis Dietético	47
6.2. Evaluación de la Base de Datos Sintética	49
6.2.1. Clasificación Binaria Mediante Umbrales	50
7. Conclusiones Finales y Trabajo Futuro	53
7.1. Conclusiones Finales	53
7.2. Limitaciones y Trabajo Futuro	54
Bibliografía	56

Índice de Figuras

2.1. Procedimiento de un sistema de evaluación dietética basado en imágenes. Adaptado de [10].	6
2.2. Imágenes de alimentos extraídas a partir de la técnica <i>Self-Collected</i> . Fuente: [24, 29, 31, 43]	9
2.3. Imágenes de alimentos extraídas a partir de la técnica <i>Web Scraping</i> . Fuente: [12, 18, 19, 48]	10
2.4. Imágenes de alimentos con algún tipo de error. Fuente: [12,40]	11
2.5. Imágenes de alimentos extraídas de bases de datos combinadas. Fuente: [6, 22, 30, 33]	12
2.6. Pirámide de la Alimentación Saludable de la Sociedad Española de Nutrición Comunitario (SENC).	15
3.1. Proceso de categorización de los productos. En este caso, se ha tomado como ejemplo el producto «espaguetis a la boloñesa».	23
3.2. Ejemplos de algunas imágenes de productos que se encuentran en la base de datos generada. Se han dividido por categorías y subcategorías.	25
4.1. Ejemplos de dietas de un día de algunos usuarios pertenecientes a la base de datos sintética. Por perfiles, de arriba a abajo: perfil 1 (sano), perfil 2 (insano), perfil 3 (medio) y perfil 8 (consumo excesivo de carne).	39
6.1. Análisis de dos frecuencias de ingesta de diferentes grupos alimentarios. En la gráfica de arriba, se observa un usuario con un perfil de hábito alimentario saludable, mientras que en la gráfica de abajo, corresponde con un perfil insano. Para cada grupo de alimento, se indica en la figura los rangos óptimos (en color verde) para una dieta saludable según los organismos internacionales.	48
6.2. Distancia de Mahalanobis Aplicada a los Usuarios de la Base de Datos Sintética.	50

Índice de Tablas

2.1. Bases de datos de imágenes de alimentos que conforman el Estado del Arte. Para cada una de las bases de datos se describe el número de imágenes y categorías de alimentos, la región donde se encuentran los platos, el año de publicación y el tipo de adquisición.	8
2.2. Estado del Arte de los diferentes métodos de clasificación por tipo de alimentos. En negrita , se muestran los resultados con mejores rendimientos tanto en <i>Top 1</i> como en <i>Top 5</i>	13
2.3. Tabla con las frecuencias recomendadas dependiendo del grupo de alimentos al que pertenezca Fuente: SENC.	17
3.1. Bases de datos alimentos que han sido seleccionadas para el presente estudio. Para cada una, se describe el número de imágenes y categorías de alimentos, la región donde se encuentran los productos y el año de publicación. Se muestra también el enlace de descarga de cada una de ellas.	20
3.2. Categorías y subcategorías definidas en la base de datos propuesta.	29
4.1. Parámetros asociados a las características de la dieta.	32
4.2. Parámetros asociados a los grupos alimentarios (tabla de la izquierda) y a los grados de ingesta (tabla de la derecha).	33
4.3. Parámetros asociados al pan y bebidas.	34
4.4. Perfiles creados para la base de datos sintética.	35
4.5. Ejemplos de perfiles con sus respectivos parámetros. *s.s. semana sana, s.i. = semana insana.	37
5.1. Bases de datos evaluadas que pertenecen al Estado del Arte.	42
5.2. Protocolos definidos para los 5 experimentos propuestos.	43
5.3. Resultados obtenidos en evaluación para las bases de datos correspondientes al Estado del Arte.	44
5.4. Rendimientos obtenidos en evaluación para los diferentes experimentos realizados de la base de datos de alimentos y grupos alimentarios generada. En negrita se señalan los mejores resultados en cada escenario.	45

1

Introducción

Según la Organización Mundial de la Salud (OMS), se estima que el **39 %** de la población adulta tiene **sobrepeso** y que para 2030, esta cifra alcanzará el 50 %. Además, la aparición de **enfermedades no transmisibles** (ENT) se ha multiplicado en el último siglo debido principalmente a un **pésimo hábito alimentario**. Estas enfermedades, como la diabetes, causa millones de muertes al año, por lo que adoptar un plan de alimentación equilibrado es necesario para reducir la aparición de este tipo de trastornos [1].

El cuerpo humano necesita un amplio rango de nutrientes para el correcto funcionamiento del mismo, por lo que una deficiencia alimentaria supone un mayor riesgo de padecer ENT. No obstante, la alimentación de hoy en día destaca por la **escasez** de cantidad de alimentos que contienen cereales, frutas o verduras y en cambio, el alto consumo de productos procesados, bebidas azucaradas y carnes rojas contribuye a la aparición de todas estas enfermedades [2]. La alimentación tiene un **impacto directo** en la salud de una persona y por ello se necesitan nuevas soluciones que aborden este tipo de problemas [3].

Las estrategias que se han utilizado en las últimas décadas se han basado en recomendaciones dirigidas a la **población en general** y los resultados han confirmado que este tipo de remedios siguen siendo ineficaces. Por lo tanto, se requieren de medidas más **personalizadas** que analicen de manera más individualizada a la persona para posteriormente determinar su dieta. Por estos motivos, se espera que la **nutrición personalizada** sea una de las mayores revoluciones de la medicina actual [4].

1.1. Motivación del Proyecto

Con el gran desarrollo de las tecnologías digitales, hoy en día se almacenan millones de datos relacionados con la salud y alimentación de una persona. De este modo, se ha generado un gran volumen de datos asociado a la alimentación y a la que se la ha denominado informática de los alimentos, o en inglés, *food computing*. Esta rama, además, se encarga de aplicar soluciones informáticas a los problemas relacionados con la alimentación que han surgido en los últimos años [5].

Por otra parte, con la proliferación de las redes sociales, nuevas tendencias han ido apareciendo. Una de ellas se relaciona directamente con *food computing*, la cual consiste en tomar

fotografías de alimentos que se vayan a consumir en ese momento. Por ello, el número de imágenes de platos de comida ha crecido de manera exponencial y a raíz de ello, han surgido aplicaciones que se basan en el reconocimiento de los alimentos por medio de sistemas automáticos [6]. Concretamente, los sistemas de reconocimiento basados en **Inteligencia Artificial** (IA) han demostrado ser los más efectivos de cara a la identificación de un plato de comida.

Al mismo tiempo, se ha generado una necesidad de evaluar los diferentes alimentos que se consumen a lo largo del día y los métodos tradicionales se han quedado obsoletos [7]. Asimismo, el acceso a internet y la integración de cámaras a los teléfonos móviles permiten una implementación de herramientas que evalúen la dieta de una manera más personalizada [8]. Sin embargo, la falta de bases de datos que contemplen la dieta de una persona dificulta la labor de desarrollar estas herramientas.

Por estos motivos, este Trabajo de Fin de Máster (TFM) supone un primer estudio hacia la **evaluación de la salud a partir de los hábitos alimenticios**. Para ello, se ha desarrollado el primer entorno programable que permite, de forma automática, la **creación de bases de datos sintéticas que reflejan distintos tipos de perfiles de hábitos de comportamiento alimenticio**. Esta herramienta además, evaluará desde un punto de vista objetivo, el estado nutricional de las personas, lo que permitirá un análisis real de la dieta en cada una de ellas.

1.2. Objetivos y Enfoque

Uno de los principales objetivos de este TFM reside en desarrollar un entorno capaz de generar diferentes perfiles de hábitos de comportamiento alimenticio. Para ello, se han marcado una serie de objetivos previos de manera que se adquieran los conocimientos necesarios:

- Estudio de los métodos computacionales que se aplican en el mundo de la alimentación (*food computing*).
- Estudio en profundidad de las diferentes bases de datos de imágenes de alimentos que conforman el Estado del Arte.
- Estudio de los métodos automáticos que se centran en el reconocimiento de alimentos a partir de imágenes.
- Estudio de los hábitos alimentarios según las recomendaciones de diferentes organismos nacionales e internacionales.
- Estudio de los diferentes sistemas de recomendación basados en la alimentación que se encuentran en el Estado del Arte.
- Creación de una base de datos de imágenes de alimentos que contemple todos los grupos alimentarios.
- Implementación de un entorno programable que sea capaz de generar una base de datos sintética que reflejen diferentes tipos de perfiles de hábitos de comportamiento alimenticio.
- Evaluación exhaustiva de los métodos automáticos desarrollados frente a la base de datos de imágenes generada.
- Análisis y evaluación en profundidad de la base de datos sintética que se ha creado.
- Estudio de metodologías y sistemas que posibiliten una mejora del trabajo propuesto en un futuro.

1.3. Metodología y Plan de Trabajo

Para cumplir de manera efectiva con los objetivos descritos anteriormente, se ha seguido el siguiente plan de trabajo:

- **Estudio del Estado del Arte:** para poder realizar las diferentes tareas, se ha de adquirir previamente una formación que abarque los campos en el que se encuentra el presente trabajo. Se ha efectuado un estudio profundo en: *food computing*, bases de datos de imágenes de alimentos, métodos automáticos de reconocimiento de alimentos a partir de imágenes y hábitos alimentarios que siguen una serie de recomendaciones saludables.
- **Creación de una base de datos de imágenes de alimentos:** mediante un análisis previo de las bases de datos que conforman el estado del arte, se ha creado un conjunto de datos a partir de las imágenes de algunas de estas bases de datos. Para ello, se ha tenido en cuenta los diferentes productos alimenticios que se encuentran en cada una, por lo que la nueva base de datos contará con numerosos y diferentes productos únicos.
- **Implementación y desarrollo del entorno:** se ha diseñado un entorno programable capaz de generar una base de datos sintética a partir de una serie de parámetros iniciales. De esta manera, se ha creado una base de datos teniendo en cuenta varios perfiles que reflejan diferentes hábitos de comportamiento alimenticio.
- **Estudio y desarrollo del software existente:** tras analizar algunos de los métodos automáticos de reconocimiento de alimentos, se ha optado por utilizar aquellos basados en IA.
- **Evaluación de los experimentos y resultados obtenidos:** en primer lugar, se ha establecido una serie de experimentos que evalúan las diferentes características de la base de datos de imágenes generada. Tras la obtención de los resultados, se han comparado los diferentes rendimientos con el fin de analizar posibles mejoras tanto en la base de datos como en el método de reconocimiento. Por otro lado, se ha analizado la base de datos sintética que se ha creado, comparando los usuarios con perfiles similares y distintos. De esta manera, se ha evaluado la calidad del entorno, así como la calidad de la dieta de cada usuario.
- **Redacción de la memoria:** finalmente, se elabora la presente memoria tras completar el estudio que se ha llevado a cabo en el Trabajo de Fin de Máster. Para ello, se ha tenido en cuenta la estructura que se detalla en la Sección 1.4.

1.4. Organización de la Memoria

La presente memoria está formado por los siguientes capítulos:

- **Capítulo 1:** Introducción.
- **Capítulo 2:** Estado del Arte.
- **Capítulo 3:** Base de Datos de Alimentos y Grupos Alimentarios.
- **Capítulo 4:** Hábitos de Comportamiento Alimenticio: Entorno Programable.
- **Capítulo 5:** Experimentos: Base de Datos de Alimentos y Grupos Alimentarios.

- **Capítulo 6:** Experimentos: Base de Datos de Hábitos de Comportamiento Alimenticio.
- **Capítulo 7:** Conclusión y Trabajo Futuro.

2

Estado del Arte

En este capítulo se analiza el impacto que tiene la Inteligencia Artificial en el campo de la alimentación y en sus diversos ámbitos que la componen. Tras un estudio exhaustivo del denominado *food computing*, se muestran las recomendaciones que algunas organizaciones (a nivel nacional e internacional) aconsejan para llevar una vida saludable a partir de su dieta, así como algunos sistemas de recomendación de dietas saludables que se encuentran en el Estado del Arte.

2.1. *Food Computing*

Food computing es un término asociado a la aplicación de métodos computacionales en el mundo de la alimentación. De este modo, tecnologías actuales como *computer vision*, *data mining* o *machine learning* se aplican al gran volumen de datos heterogéneos que existen sobre nutrición que se han generado en las últimas décadas. Este tipo de información tan dispar como imágenes de alimentos, recetas de comidas o registros asociados a la alimentación, entre otros, son recolectados y analizados de una forma precisa y eficiente.

En el estudio donde se refieren al término *food computing* [9], los autores indican que la procedencia de todos estos datos pertenecen principalmente a tres fuentes: **páginas web** como *Meituan*, *Yummly* o *foodspotting*; **plataformas sociales** como es el caso de *Twitter*, *Instagram* o *YouTube*; y las **cámaras** personales, que con la adaptación de estas a los teléfonos inteligentes y otros dispositivos móviles ha incrementado en gran medida el volumen de datos. Dado que un porcentaje alto de la información procedente de las fuentes mencionadas es de carácter visual (imágenes y vídeos), como resultado, los datos multimedia se han agrupado en 2 tipos: **imágenes de alimentos**, de las que derivan numerosas bases de datos que se encuentran hoy públicas (véase Sección 2.2.1); y vídeos de cocina, en los que se pueden encontrar multitud de actividades filmadas que se encuentran en el ámbito culinario. Por otra parte, la información de **carácter textual** se divide a su vez en varios tipos, entre los que destacan: recetas de comidas, información sobre las propiedades de los alimentos, ontologías de los alimentos, registros asociados a la alimentación u otros tipos de datos menos abundantes (como cuestionarios culinarios). Entre la gran variedad de tareas que se aplican en este campo, en este presente TFM se centra en el reconocimiento de hábitos de comportamiento alimenticio a través de las imágenes, y en concreto, en la **clasificación de alimentos**.

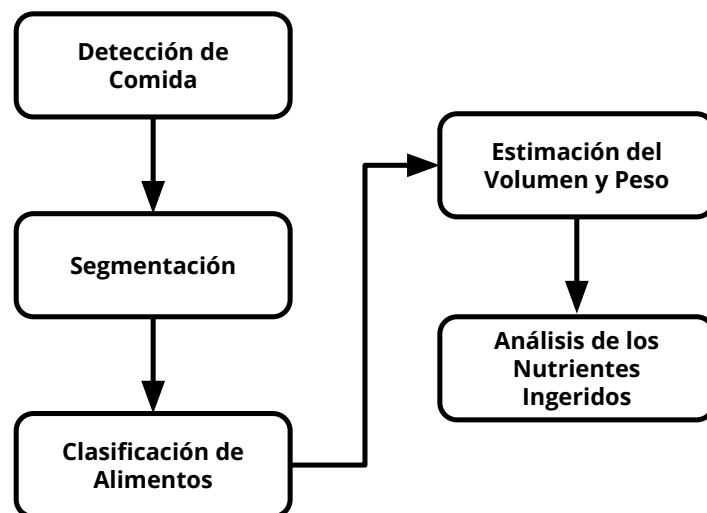


Figura 2.1: Procedimiento de un sistema de evaluación dietética basado en imágenes. Adaptado de [10].

2.1.1. Reconocimiento de Alimentos

Como se ha comentado previamente, las cámaras que incorporan la mayoría de estos dispositivos inteligentes juegan un rol crucial a la hora de proporcionar información valiosa: de esta manera, los sistemas automáticos basados en imágenes son capaces de reconocer y diferenciar los diferentes alimentos que se encuentran en una comida, estimar su volumen o incluso calcular su valor nutricional [10]. Por lo tanto, una imagen que es procesada para tal fin sigue un procedimiento similar al que se observa en la Figura 2.1, en el que cuenta con 5 fases consecutivas: i) detección de comida, ii) segmentación, **iii) clasificación de tipo de comida**, iv) estimación del volumen y peso, y finalmente v) evaluación y análisis sobre los nutrientes ingeridos.

La primera fase, por tanto, se refiere a la detección de un plato de comida o de alimentos en una imagen. Posteriormente, las imágenes son segmentadas en base a un criterio previamente establecido: en algunos estudios, esta segmentación trata de localizar los diferentes platos que se encuentran en una imagen, mientras que en otros se centran en ubicar los diferentes alimentos e ingredientes que componen un único plato [3]. Por otra parte, la **fase de clasificación** de tipo de comida es descrita en la Sección 2.2.

Finalmente, las dos últimas fases (estimación del volumen y análisis de los nutrientes ingeridos) tienen que ver con la evaluación dietética asistida por imágenes, o en inglés, *image-assisted dietary assessment*, el cual es un término que se asocia a cualquier método que usa contenido multimedia durante las comidas para analizar la ingesta calórica y nutricional. Además, en la última década ha habido un incremento en el uso de móviles y dispositivos *wearable* que monitorizan los comportamientos relacionados con la alimentación y la actividad física [11].

A su vez, es una manera de mejorar los métodos tradicionales que se basan principalmente en cuestionarios (que parten de la subjetividad del usuario y que dependen de la memoria del mismo) y se rige por dos métodos o tipos de captura: **métodos activos**, por un lado, que requieren de una captura continua de las comidas y alimentos que se consumen; y **métodos pasivos**, por otro lado, en donde la persona porta en todo momento una cámara que analiza la ingesta de los alimentos por parte del usuario [12, 13]. No obstante, aunque han sido foco de estudio en numerosos artículos, los resultados logrados no han sido consistentes debido a la gran variabilidad que presenta un alimento, ya que un cambio en su aspecto o en su composición puede modificar su volumen o incluso su valor nutricional [3].

2.2. Clasificación de Alimentos

En la actualidad, las **imágenes** que presentan algún tipo de **alimento** son uno de los datos multimedia más comunes y aportan tanto información visual como semántica [9]. Como se ha descrito anteriormente, analizar grandes volúmenes de datos contribuye enormemente al desarrollo de herramientas implementadas en diferentes sectores y por ello, en la Sección 2.2.1 se describen las **bases de datos de imágenes de alimentos** que conforman el Estado del Arte. Además, estas bases de datos son evaluadas por diferentes métodos que facilitan la **clasificación del alimento** (véase Sección 2.2.2).

2.2.1. Bases de Datos

En esta sección se detallan las distintas bases de datos compuestas por imágenes de alimentos que se encuentran hoy en día. Desde las primeras bases de datos como **PFID** publicada en 2009 hasta las más recientes, como es el caso de **Food2K** (2021), la cual cuenta con un total de 2000 categorías y alrededor de un millón de imágenes de productos alimentarios [14, 49].

En la Tabla 2.1 se enumeran las distintas bases de datos que conforman el Estado del Arte. En ella se han anotado una serie de características de cada una de ellas: el número de categorías e imágenes de alimentos que la componen, la región donde pertenecen los platos, el año, el tipo de adquisición y el tipo de anotación. Además, para aquellas que se encuentran disponibles hay habilitado un enlace. Por un lado, se diferencia notablemente aquellas bases de datos que contienen grupos de alimentos generales como pan, pasta, arroz, etc. ya que el número de categorías es relativamente pequeño (menos de 30) y un número alto de imágenes (más de mil), como puede ser el caso de *Food-11* [30]. Estas se refieren a su vez como bases de datos de grano grueso (coarse-grained) frente a las de grano más fino (*fine-grained*), las cuales aportan un número de categorías alto. Además de ello, un mismo plato puede estar presentado de diferentes formas, cantidades o colores, por lo que aumenta la complejidad del problema.

Tras un análisis preliminar, las bases de datos se pueden dividir dependiendo de cómo haya sido el protocolo de captura, es decir, el tipo de adquisición. En este caso se diferencian 3 tipos: *self-collected*, *web scraping* o a partir de otras bases de datos (**combinación**).

Self-Collected

Las bases de datos *Self-Collected* son aquellas que se han obtenido tras una captura propia, es decir, las imágenes se han tomado sin la intervención de otras bases de datos adicionales o de técnicas de recolección de imágenes. Además, tienen la característica de haberse capturado en entornos controlados o semi-controlados, por lo que los procedimientos de captura han sido similares para cada imagen. Por ejemplo, **PFID** es una de las primeras bases de datos de imágenes de alimentos que se incorporó en la literatura [14]. Creada en 2009 y con un total de 101 clases y 4.545 imágenes de 11 cadenas de restaurantes de comida rápida de Estados Unidos, esta base de datos incluye comidas como hamburguesas, pizzas o bocadillos, entre otros. Otros ejemplo son **FoodPics Extended** [43] (ampliación de *FoodPics* [50]) y **Full4Health (F4H)** [31], donde las imágenes se caracterizan por situarse sobre un fondo plano, consiguiendo eliminar cualquier ruido extra ocasionado por el escenario.

Con más de 15.000 imágenes se encuentra **FruitVeg-81** [32], la primera base de datos que cuenta exclusivamente con imágenes de 53 frutas y verduras diferentes y un total de 81 subcategorías. La captura se realizó con teléfonos móviles en tiendas de la cadena multinacional *SPAR* y para cada uno de los productos se tuvo una gran variedad de aspectos: una misma fruta o verdura puede presentarse con diferentes apariencias visuales, escala, iluminación o número de

Tabla 2.1: Bases de datos de imágenes de alimentos que conforman el Estado del Arte. Para cada una de las bases de datos se describe el número de imágenes y categorías de alimentos, la región donde se encuentran los platos, el año de publicación y el tipo de adquisición.

Base de Datos	Categorías/Imágenes	Región	Año	Adquisición
PFID ¹ [14]	101 / 4.545	Occidente	2009	<i>Self-Collected</i>
Food50 [15]	50 / 5.000	Japón	2010	<i>Web Scraping</i>
Food85 [16]	85 / 8.500	Japón	2010	<i>Web Scraping</i>
UECFood-100 ² [17]	100 / 14.361	Japón	2012	<i>Web Scraping</i>
UECFood-256 ³ [18]	256 / 31.395	Japón	2014	<i>Web Scraping</i>
Diabetes [2]	11 / 4.868	Misc.	2014	<i>Web Scraping</i>
Food-101 ⁴ [19]	101 / 101.000	Occidente	2014	<i>Web Scraping</i>
UPMCD Food-101 ⁵ [20]	101 / 90.840	Occidente	2015	<i>Web Scraping</i>
Dishes [21]	3.832 / 117.504	China	2015	<i>Web Scraping</i>
Food201-Segmented ⁶ [22]	201 / 10.100	Occidente	2015	Combinación
UNIMIB2015 ⁷ [23]	15 / 2.000	Misc.	2015	<i>Self-Collected</i>
UNIMIB2016 ⁸ [24]	73 / 1.027	Misc.	2016	<i>Self-Collected</i>
UNICT-FD889 ⁹ [25]	889 / 3.583	Misc.	2016	<i>Self-Collected</i>
Instagram 800k [26]	43 / 808.964	Misc.	2016	<i>Web Scraping</i>
VireoFood-172 ¹⁰ [27]	172 / 110.241	China	2016	<i>Web Scraping</i>
Food500 [28]	508 / 148.408	Misc.	2016	<i>Web Scraping</i>
UNICT-FD1200 ¹¹ [29]	1.200 / 4.754	Misc.	2016	<i>Self-Collected</i>
Food-11 ¹² [30]	11 / 16.643	Misc.	2016	Combinación
F4H ¹³ [31]	377 / 377	Misc.	2016	<i>Self-Collected</i>
FruitVeg-81 ¹⁴ [32]	81 / 15.737	Misc.	2017	<i>Self-Collected</i>
Food524DB ¹⁵ [33]	524 / 247.636	Misc.	2017	Combinación
ChineseFoodNet ¹⁶ [34]	208 / 192.000	China	2017	Combinación
TurkishFoods-15 ¹⁷ [35]	15 / 7.500	Turquía	2017	<i>Web Scraping</i>
Indian Food Database [36]	50 / 5.000	India	2017	<i>Web Scraping</i>
THFood-50 [37]	50 / 700	Tailandia	2017	<i>Web Scraping</i>
VegFru ¹⁸ [38]	292 / 160.000	Misc.	2017	<i>Web Scraping</i>
ISIA Food-200 ¹⁹ [39]	200 / 197.323	Misc.	2019	<i>Web Scraping</i>
MAfood-121 ²⁰ [6]	121 / 21.175	Misc.	2019	Combinación
FoodX-251 ²¹ [40]	251 / 158.846	Misc.	2019	<i>Web Scraping</i>
KenyanFood13 ²² [41]	13 / 8.174	Kenia	2019	<i>Web Scraping</i>
Sushi50 ²³ [42]	50 / 3.963	Japón	2019	<i>Web Scraping</i>
Food-Pics Extended ²⁴ [43]	7 / 896	Misc.	2019	<i>Self-Collected</i>
FoodAI-756 [44]	756 / 400.000	Misc.	2019	<i>Web Scraping</i>
Mixed-Dish [45]	164 / 9.254	Asia	2019	<i>Self-Collected</i>
VireoFood-251 ²⁵ [46]	251 / 169.673	China	2020	<i>Web Scraping</i>
Pakistani Food Dataset [47]	100 / 4.928	Pakistan	2020	<i>Web Scraping</i>
ISIA Food-500 ²⁶ [48]	500 / 399.726	Misc.	2020	<i>Web Scraping</i>
VIPER-FoodNet ²⁷ [12]	82 / 17.881	EE.UU.	2020	<i>Web Scraping</i>
Food2K ²⁸ [49]	2.000 / 1.036.564	Misc.	2021	<i>Web Scraping</i>

¹<http://vireo.cs.cityu.edu.hk/VireoFood172/> ²<http://foodcam.mobi/dataset100.html> ³<http://foodcam.mobi/dataset256.html> ⁴http://data.vision.ee.ethz.ch/cvl/datasets_extra/food-101/ ⁵<http://visiir.lip6.fr/> ⁶<https://storage.googleapis.com/food201/> ⁷<http://www.ivl.disco.unimib.it/activities/food-recognition/> ⁸<http://www.ivl.disco.unimib.it/activities/food-recognition/> ⁹<https://iplab.dmi.unict.it/UNICT-FD889/> ¹⁰<http://vireo.cs.cityu.edu.hk/VireoFood172/> ¹¹<https://iplab.dmi.unict.it/UNICT-FD1200/> ¹²<https://www.kaggle.com/vermaavi/food11> ¹³<https://osf.io/cx7tp/> ¹⁴<https://www.tugraz.at/institute/icg/research/team-bischof/lrs/downloads/fruitveg81/> ¹⁵<http://www.ivl.disco.unimib.it/activities/food524db/> ¹⁶<https://sites.google.com/view/chinesefoodnet/> ¹⁷<https://vision.cs.hacettepe.edu.tr/data.php> ¹⁸<https://github.com/ustc-vim/vegfru> ¹⁹<http://123.57.42.89/FoodComputing-Dataset/FoodComputing-ISIA200.html> ²⁰<http://www.ub.edu/cvub/mafood121/> ²¹<https://www.kaggle.com/c/food-2019-figvc6/data> ²²<https://github.com/monajalal/Kenyan-Food> ²³<http://www.doc.ic.ac.uk/~jq916/Sushi-50.zip> ²⁴<https://sites.google.com/site/eatingandxietylab/resources/food-pics> ²⁵<http://vireo.cs.cityu.edu.hk/vireo-251/> ²⁶<http://123.57.42.89/FoodComputing-Dataset/ISIA-Food500.html> ²⁷<https://lorenz.ecn.purdue.edu/~vfn/> ²⁸<https://www.kaggle.com/c/largefinefoodai-iccv-recognition>

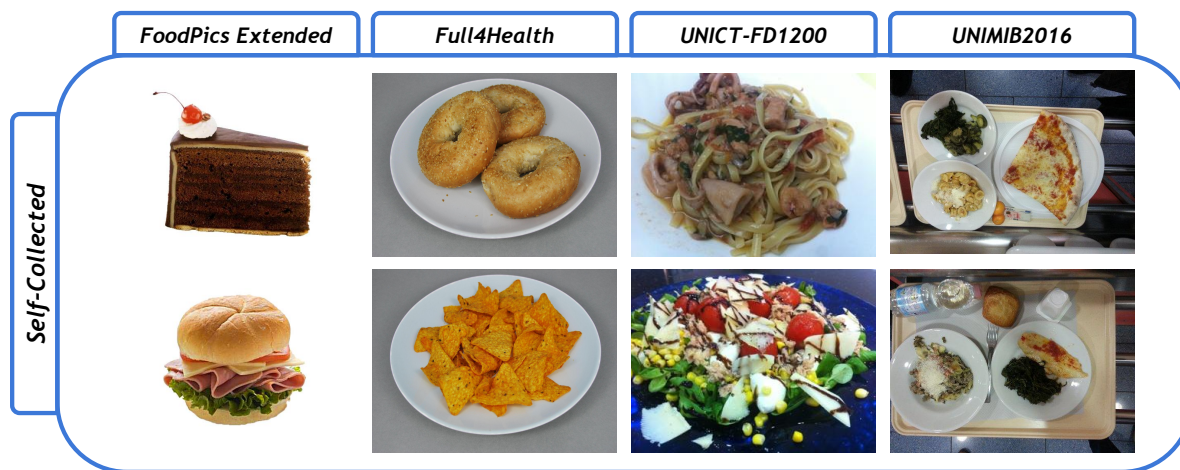


Figura 2.2: Imágenes de alimentos extraídas a partir de la técnica *Self-Collected*. Fuente: [24, 29, 31, 43]

elementos, entre otros. Al igual que *FruitVeg-81*, las imágenes de *UNICT-FD889* y *UNICT-FD1200* se han adquirido mediante fotografías tomadas por teléfonos móviles y en diferentes entornos y condiciones variables [25, 29]. Ambas bases de datos publicadas por *Farinella et al.*, contienen platos de diferentes regiones del mundo y cada uno de ellos ha sido fotografiado en varias tomas para garantizar las variabilidades geométricas y fotométricas que ofrecen. *UNIMIB2015* [23] y *UNIMIB2016* [24] son dos bases de datos adquiridas en entornos reales y controlados (en este caso en un comedor universitario), en las que se muestran imágenes de bandejas de comida con los diferentes platos que puede haber en ella y son identificados mediante polígonos que cubren la superficie de cada alimento. *UNIMIB2015* cuenta con 2.000 imágenes y 15 categorías, mientras que en *UNIMIB2016*, se han obtenido menos imágenes (1.027) pero con mayor variedad (73 categorías). De igual manera, las imágenes obtenidas en *Mixed-Dish* se han tomado en diferentes comedores escolares asiáticos [45]. En último lugar, *Food-975* cuenta con 975 platos típicos chinos y más de 37.000 imágenes capturadas en 6 restaurantes [51]. Algunos ejemplos se pueden observar en la Figura 2.2.

Web Scraping

Por otra parte, se encuentran otras bases de datos cuya adquisición se ha obtenido a partir de la técnica *Web Scraping*. En este caso, consiste en recolectar imágenes de alimentos a partir de diferentes plataformas web y plataformas sociales, como se observa en la Figura 2.3. Normalmente, el número de imágenes que se obtienen se encuentran en el orden de decenas o centenas de miles y algunas bases de datos no han contemplado un preprocesamiento de las imágenes: algunas de ellas aparecen con texto, con marcas de agua, el producto se encuentra en un segundo plano o directamente la imagen que se muestra no tiene nada que ver con el plato en cuestión (véase Figura 2.4).

En primer lugar, existen bases de datos con imágenes de alimentos típicos de ciertos países del mundo: India, Turquía o Kenia son algunos de estos ejemplos, aunque se pueden encontrar más en la Tabla 2.1 [35, 41, 36, 37, 47]. *VIPER-FoodNet*, por su parte, está compuesta por imágenes de comidas consumidas en Estados Unidos, incluyendo casi 15.000 imágenes repartidas en 82 categorías diferentes [12]. *Food-101*, es una base de datos que se ha creado a partir de imágenes provenientes de la plataforma *Foodspotting*, la cual ha sido usada mayoritariamente por población de occidente [19]. Con 101 categorías y 1.000 imágenes por categoría, la suma total alcanza las 101.000 imágenes. Otra base de datos muy similar a esta última es *UPMC*



Figura 2.3: Imágenes de alimentos extraídas a partir de la técnica *Web Scraping*. Fuente: [12, 18, 19, 48]

Food-101, la cual incluye el mismo número de categorías (101) y 90.840 imágenes de comidas típicas de occidente [20].

Tanto **UECFood-100** [17] como **UECFood-256** [18] son bases de datos generadas a partir de comidas típicas de Japón, aunque ambas incluyen algún plato de carácter internacional (como pizza o patatas fritas). Además, estas bases de datos proporcionan la localización de los alimentos mediante *bounding boxes*. De manera similar se encuentran otros conjuntos de datos con un tipo de anotación rectangular (*bounding box*), como son los casos de **VireoFood-172** y **VireoFood-251**, los cuales cuentan con más de 100.000 imágenes [27, 46]. En este caso, en vez de identificar alimentos de mayor tamaño, se centran en los ingredientes que componen cada comida.

Por otro lado, existen bases de datos con imágenes de platos típicos que representan distintas regiones del planeta. Un ejemplo de ello es **ISIA Food-200** y su versión actualizada **ISIA Food-500**, las cuales son dos bases de datos publicadas por *Min et al.* en 2019 y 2020, respectivamente [39, 48]. Tal y como se indica en sus nombres, la primera de ellas tiene un total de 200 categorías y alrededor de 200.000 imágenes, mientras que la segunda (**ISIA Food-500**) contiene un total de 500 categorías y cerca de 400.000 imágenes de platos de diferentes regiones del mundo. Al igual que **FruitVeg-81**, la base de datos **VegFru** está compuesta solamente por frutas y verduras, salvo que en este caso, el número de categorías y subcategorías es mucho mayor: 25 y 292, respectivamente. **Instagram 800k** es una base de datos de imágenes extraídas de la plataforma social *Instagram*, que cuenta con más de 800.000 imágenes y 43 categorías. Además, incluyen metadatos de cada imagen como comentarios, ubicación o *hashtags*, entre otros [26]. **Diabetes**, por otra parte, es una base de datos creada con el fin de proporcionar un sistema de reconocimiento de alimentos para pacientes con diabetes [2]. En último lugar se encuentra una de las bases de datos más recientes y con un impacto mayor en comparación con el resto: **Food2K** es la base de datos más grande publicada hasta la fecha, con más de 2.000 categorías y en torno a 1.000.000 de imágenes. Las imágenes se han obtenido de la página web *Meituan*, la cual almacena un gran número de imágenes de platos tomadas por los propios trabajadores de restaurantes y clientes de los mismos. Además, *Min et al.*, autores de las bases de datos **ISIA Food-200** y **ISIA Food-500**, incluyen una ontología de alimentos en la que organizan todos los platos en 12 superclases o categorías principales (como vegetales, pan, postres, o pescados, entre otros) y multitud de subclases derivadas de ellas [49].



Figura 2.4: Imágenes de alimentos con algún tipo de error. Fuente: [12,40]

Bases de Datos Combinadas

Otra manera de crear nuevas bases de datos es a partir de otras ya existentes: **Food-11** se compone de 16.643 imágenes repartidas en 11 categorías principales (similares a *Food2k*) [30]. Esta base de datos se ha creado a partir de 3 conjuntos de imágenes de alimentos (*Food-101*, *UECFood-100* y *UECFood-256*) y de 2 plataformas sociales (*Flickr* e *Instagram*) para completar algunas de las categorías con menor presencia. De igual modo, **Food524DB** se creó a partir de las bases de datos *VireoFood-172*, *Food-101*, *Food50* y una versión modificada de *UECFood-256* [33]. **Food201-Segmented**, por su parte, es una base de datos formada a partir de otra con mayor volumen (*Food101*) y que cuenta con alrededor de 10.000 imágenes [22]. Para la siguiente base de datos denominada **Multi-Attribute Food (MAfood-121)**, Aguilar. et al. han seleccionado las 11 cocinas más populares a nivel global (de acuerdo con *Google Trends*) con el fin de crear un conjunto de datos de 121 categorías y con más de 21.000 imágenes obtenidas a partir de diferentes bases de datos como *Food-101*, *UECFood256*, *TurkishFoods-15* y una base de datos privada [6]. Algunos ejemplos de las bases se muestran en la Figura 2.5.

2.2.2. Clasificación de Alimentos

Tras analizar las bases de datos de imágenes de productos alimenticios que existe en la literatura, es conveniente estudiar los métodos de **clasificación** de los alimentos evaluadas en las descritas bases de datos. Aunque al principio se usaran técnicas *handcrafted*, la aparición de métodos basados en *Deep Learning* ha generado un aumento en el rendimiento en comparación con los métodos más tradicionales. El empleo de redes neuronales artificiales o en inglés, *Artificial Neural Network* (ANN) es la opción más eficiente en términos de computación y de rendimiento: concretamente, las redes neuronales convolucionales -*convolutional neural network*- (CNN), son un tipo de redes neuronales artificiales que se utilizan para este tipo de problemas relacionados con el tratamiento y clasificación de imágenes [6].

Antes de proceder a ellas, se ha de describir las métricas empleadas en cada uno de los estudios: en este caso, la más empleada es el **accuracy** (Acc), el cual indica el porcentaje de aciertos que ha tenido el sistema frente al número total de imágenes evaluadas. En los estudios se muestran tanto *Top 1 Acc*, es decir, teniendo solo en cuenta la mejor predicción del sistema y *Top 5 Acc*, donde es un acierto válido si el modelo ha predicho la clase correcta entre las 5 con mayor probabilidad.

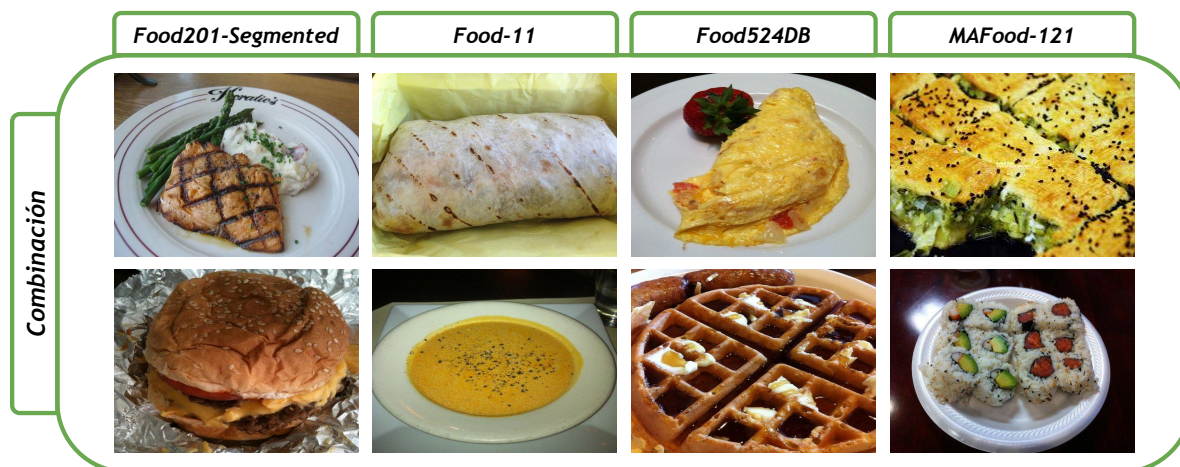


Figura 2.5: Imágenes de alimentos extraídas de bases de datos combinadas. Fuente: [6, 22, 30, 33]

Técnicas Tradicionales

En primer lugar, los métodos tradicionales utilizados para la clasificación se rigen por 2 procesos principales: **extracción de características** y **clasificación final**. La primera parte se centra en la detección de características visuales que permiten identificar el tipo de comida a partir de su forma, color o textura [10]. De este modo, descriptores como *Scale Invariant Feature Transform (SIFT)*, *Histogram Oriented Gradients (HOG)* o *Local Binary Patterns (LBP)* y otras técnicas como *Bag of Features (BoF)* o filtros de *Gabor* se han aplicado en numerosos estudios para tal fin [52, 53, 54, 55]. Por otra parte, *Support Vector Machine (SVM)* y *K-Nearest Neighbour (KNN)* son los clasificadores más comunes a la hora de separar los diferentes tipos de comida. Aunque algunos de estos métodos tradicionales alcanzan rendimientos por encima del 70 % de *accuracy* [56, 57, 58], este tipo de soluciones no son aplicables a problemas de mayor magnitud: por un lado, estos métodos se han entrenado y evaluado con bases de datos propias o de un tamaño muy poco significativo y con grandes diferencias visuales entre categorías; por otro lado, ante bases de datos más desafiantes, esto es, con un número alto de imágenes y poca variabilidad entre clases, se ha optado por el uso de métodos más eficientes, como se detalla a continuación.

Técnicas de *Deep Learning*

En este caso, las CNN junto con otras ANN y arquitecturas más complejas, se encargan tanto de extraer características como de clasificar las diferentes imágenes y de este modo, han resultado ser efectivas a la hora de identificar los diferentes tipos de comida. Tal y como se detalla en la Tabla 2.2, se muestran diferentes métodos propuestos junto con los rendimientos que se han obtenido ante distintas bases de datos (en **negrita** se destacan los métodos que han logrado mayor *accuracy* tanto en *Top 1* como en *Top 5*). Cabe destacar que cada una de ellas tiene características únicas que las diferencian del resto, por lo que los resultados no son comparables, aunque dan una idea sobre la complejidad de alguna de ellas: con un resultado por encima del 90 % se encuentra el estudio realizado por *Tan et al.*, en el cual logran un 93 % en *Food-101* usando ***EfficientNet***, una arquitectura basada en CNN capaz de escalar en distintas dimensiones [59]. Otra arquitectura basada en redes convolucionales es *Squeeze-and-Excitation Network (SENet)*, la cual tiene una capacidad de generalización alta entre distintas bases de datos [60]. En este caso, logran un 91,45 % (*Top 1 Acc*) y un 98,62 % (*Top 5 Acc*) en *Vireo*

Tabla 2.2: Estado del Arte de los diferentes métodos de clasificación por tipo de alimentos. En negrita, se muestran los resultados con mejores rendimientos tanto en *Top 1* como en *Top 5*.

Base de Datos	Autores	Métodos Utilizados	Top 1 Acc. (%)	Top 5 Acc. (%)
PFID	<i>Tahir et al.</i> [61]	ARCIKELM	100	N/D
Food-11	<i>McAllister et al.</i> [63]	ResNet-152	91,34	N/D
UECFood-100	<i>Martinel et al.</i> [64]	WiSeR	89,58	99,23
	<i>Zhao et al.</i> [65]	JDNet	84	96,2
Food-101	<i>Min et al.</i> [49]	PRENet	91,13	98,71
	<i>Zhao et al.</i> [65]	JDNet	91,2	98,8
	<i>Tan et al.</i> [59]	EfficientNet-B7	93,0	N/D
UNIMIB2016	<i>Ciocca et al.</i> [24]	AlexNet + SVM	89,1	N/D
	<i>Aguilar et al.</i> [66]	DarkNet Framework	92,5	N/D
Vireo Food-172	<i>Min et al.</i> [49]	SENet	91,45	98,62
	<i>Min et al.</i> [48]	SGLANet	90,98	98,35
MAFood-121	<i>Aguilar et al.</i> [6]	ResNet-50	81,62	N/D
	<i>Aguilar et al.</i> [62]	RUMTL	83,82	N/D
ISIA Food-500	<i>Min et al.</i> [49]	Inception v4	66,62	89,87
	<i>Min et al.</i> [48]	SGLANet	64,74	89,12
Food2K	<i>Min et al.</i> [49]	PRENet	83,75	97,33
	<i>Hu et al.</i> [60]	SENet154	83,62	97,22

Food-172.

Aparte, algunos estudios se han centrado exclusivamente en diseñar arquitecturas que se adapten a las imágenes de alimentos. En [61], proponen una arquitectura basada en *transfer learning* que denominan **ARCIKELM** y por la que logran un 100% de *accuracy* en la base de datos *PFID*. *Aguilar et al.*, por otro lado, proponen una arquitectura integral (denominada **RUMTL**) que aborda el problema tanto de localizar el alimento como de clasificarlo, obteniendo un *accuracy* del 83,82% en la base de datos que ellos mismos publicaron (*MAFood-121*) [62]. Los autores de la base de datos *Food2K* proponen un sistema que se basa tanto en características globales como en locales [49]. De esta manera, logran un 83,75% y un 97,33% en *Top 1* y *Top 5*, respectivamente. Por último, en otro estudio realizado por *Min et al.* [39], proponen una arquitectura que también tienen en cuenta las características locales y globales para el reconocimiento de alimentos, por lo que obtienen características discriminativas a distintos niveles. Como resultado, logran un 64,74% en *Top 1 Acc* y cerca del 90% para *Top 5 Acc*, lo que indica la complejidad de esta última base de datos.

2.3. Hábitos Saludables y Dietas Personalizadas

Como se ha comentado en el Capítulo 1, la **nutrición** es uno de los pilares más fundamentales para tener una sociedad sana. Por ello, el tipo de comida que se ingiere tiene un impacto directo en la salud y en la calidad de vida de un individuo, ya que el cuerpo humano necesita una amplia variedad de nutrientes en su organismo para que funcione de manera correcta. De no ser así, la persona puede padecer graves **problemas de salud**, desde aquellos asociados a la obesidad (como la diabetes) hasta otros relacionados con problemas digestivos (como intolerancias alimentarias), entre muchos otros [3, 4].

Hoy en día, las comidas y alimentos se componen de un número muy alto de ingredientes que combinados entre sí, forman las diferentes **dietas** de cada persona. Al mismo tiempo, estas dietas dependen exclusivamente de su composición a la hora de referirse como dieta saludable y balancear adecuadamente estos nutrientes para cada persona es una tarea bastante compleja, ya que hay que tener en cuenta las características de cada uno. Una posible solución a día de hoy es seguir las guías dietéticas que aconsejan diferentes organismos nacionales e internacionales (véase Sección 2.3.1) para poder llevar una vida saludable. Estos consejos se fundamentan en herramientas como pirámides nutricionales y establecen una serie de pautas para conseguir un bienestar físico y mental [67]. A pesar de ello, estas recomendaciones de ámbito general son orientativas y no tienen en cuenta los distintos factores de cada individuo como la biología, genética, estilo de vida o gustos personales, entre otros. En consecuencia, no es una solución que contemple la variabilidad de cada uno y por ello, los nuevos estudios se enfocan hacia soluciones más individualizadas: la **nutrición personalizada**. Al contrario que las dietas genéricas, la nutrición o dieta personalizada considera las características más específicas de un sujeto tal como las **medidas antropométricas** (altura, peso y masa corporal), la **condición genética**, el **sexo**, los **gustos** y **necesidades personales** o la **actividad física**, entre otros. Por otra parte, también hay que tener en cuenta las causas sociales como la cultura, los factores sociales y económicos o la tradición. Estas nuevas estrategias permiten a las personas mantener un ritmo de vida saludable y les es beneficioso de cara a prevenir enfermedades crónicas derivadas de la alimentación [68]. Como resultado, al combinar estos métodos personalizados con herramientas automáticas surgen una serie de sistemas de recomendación basados en dietas saludables para todo tipo de personas, atendiendo a posibles enfermedades que padezcan o con la capacidad de adaptarse sea cual sea la condición del usuario [69].

2.3.1. Hábitos Saludables

Según la OMS, una dieta saludable junto con la realización de actividad física ayuda tanto a protegernos de la malnutrición como de enfermedades no transmisibles. Además, la ingesta calórica debe estar **equilibrada** con el gasto calórico y se debe limitar el consumo de grasas, azúcares y sal. Sin embargo, aunque cada persona tenga un nivel calórico diferente, los principios básicos en los que se fundamenta una alimentación saludable no varía, por lo que una dieta sana debe tener los siguientes requisitos en adultos¹:

- **Frutas, verduras y hortalizas:** comer al menos 400 gramos (o 5 porciones de frutas y verduras) al día reduce en gran medida el riesgo de padecer enfermedades derivadas de la nutrición y ayuda a mantener unos niveles equilibrados de fibra dietética.
- **Grasas:** reducir su consumo a menos del 30 % de la ingesta calórica diaria. De esta manera, se consigue prevenir un aumento de peso y de desarrollar enfermedades no transmisibles

¹<https://www.who.int/news-room/fact-sheets/detail/healthy-diet>



Figura 2.6: Pirámide de la Alimentación Saludable de la Sociedad Española de Nutrición Comunitario (SENC).

si se compatibiliza con un consumo menor del 10% de grasas saturadas y menos de 1% de grasas trans.

- **Sal, sodio y potasio:** el consumo de sodio es muy alto (entre 9 y 12 gramos diarios) en comparación con el consumo de potasio (menos de 3,5 gramos), por lo que ambas condiciones contribuyen a la hipertensión arterial y a su vez, incrementa el riesgo de padecer enfermedades coronarias y cerebrovasculares. Por lo tanto, reducir el consumo de sodio a menos de 5 gramos diarios puede prevenir la aparición de este tipo de enfermedades.
- **Azúcares:** en este caso, su consumo debería de ser menor al 10% de la ingesta calórica total para evitar la aparición de posibles enfermedades y menos del 5% para aportar beneficios adicionales para la salud.

Aparte de los organismos de carácter internacional, los organismos nacionales también adquieren un papel imprescindible de cara a ofrecer un plan dietético sano. De esta manera, organismos como la **Sociedad Española de Nutrición Comunitaria (SENC)**², establecen una serie de recomendaciones basadas en la alimentación, deporte y otros aspectos individuales. Como se observa en la Figura 2.6, la pirámide nutricional muestra los diferentes grupos de alimentos que se han estructurado según su composición en nutrientes y se han situado en diferentes **grados o niveles de sostenibilidad**, tal y como se ha indicado. Por tanto, cada grupo debe ser consumido en menor o mayor medida (cuanto más abajo, su consumo debe ser

²<https://www.nutricioncomunitaria.org/>

mayor) para mantener un estado saludable. Entre las medidas fijas que hay que tomar destacan: un fraccionamiento de la ingesta (entre 3 y 5 comidas al día en horarios regulares), un consumo opcional y moderado de bebidas fermentadas (alcohol) y una suplementación dietética y/o nutricional (vitamina D, folatos, complementos funcionales, etc.) regida por profesionales. Por otro lado, se pueden observar diferentes niveles según el grado de sostenibilidad de los diferentes grupos alimentarios, como se ha comentado:

- **Consumo opcional, ocasional y moderado.**
 - **Nivel 1:** Dulces, bollerías grasas untadas o snacks salados.
 - **Nivel 2:** Carnes rojas, procesadas y embutidos.
- **Consumo variado diario**
 - **Nivel 3:**
 - **Lácteos:** entre 2 y 3 veces por día.
 - **Pescados, carnes magras y blancas, legumbres, frutos secos y huevos:** entre 1 y 3 veces por día, alternando entre los diferentes grupos alimentarios.
 - **Nivel 4:**
 - **Verduras y Hortalizas:** entre 2 y 3 veces por día.
 - **Frutas:** entre 3 y 4 veces por día.
 - **Aceite de oliva virgen extra.**
 - **Nivel 5: pan de harina de cereales de grano entero, pasta y arroz integral, patatas, castañas y legumbres tiernas:** según el grado de actividad física.
 - **Nivel 6: mantenimiento de estilos de vida saludables:** realizar actividad física diaria de al menos 60 minutos, tener un equilibrio emocional y un balance energético, aplicar técnicas culinarias saludables y beber entre 4 y 6 vasos de agua al día.

NOTA: los niveles 4 y 5 pertenecen a los grupos de consumo en cada comida principal, por lo que su presencia tiene que estar en al menos 3 comidas diarias.

Aunque esta pirámide ofrezca una guía dirigida hacia una dieta sana con variedad de alimentos, no deja de ser algo orientativo. Por ello, esta misma organización (SENC) proporciona una distribución diaria y semanal de los diferentes grupos de alimentos que se han visto anteriormente. Esta distribución se muestra en la Tabla 2.3, donde los diferentes productos alimenticios se han agrupado según frecuencias recomendadas similares y a la que se le asocia un peso por cada ración aconsejada. Al comparar esta tabla con los diferentes niveles observados previamente, se comprueba que aquellos grupos de alimentos que se encuentran en niveles de mayor sostenibilidad (niveles del 3 al 5), tienen una frecuencia recomendada diaria, mientras que aquellos con menor nivel (niveles 1 y 2), su frecuencia pasa a ser semanal, lo que indica una clara declinación por los grupos de alimentos que se consideran en la base alimenticia y por tanto, orientados hacia una **nutrición más saludable**.

2.3.2. Sistemas de Recomendación Personalizados

Como se ha comentado anteriormente, desarrollar e implementar herramientas personalizadas al alcance del usuario es necesario para **garantizar la salud pública** [70]. Con los avances tecnológicos actuales, se han diseñado sistemas de recomendación para ciertos grupos sociales o que padecen ciertas enfermedades que elevan el **nivel nutritivo** de estas personas. No obstante, aunque son estudios pioneros, la mayoría de ellos se focalizan en los niveles calóricos y

Tabla 2.3: Tabla con las frecuencias recomendadas dependiendo del grupo de alimentos al que pertenezca Fuente: SENC.

Grupos de Alimentos	Frecuencia Recomendada	Peso de cada ración	Nivel de Sost.
Patatas, arroz, pan, pan integral y pasta	4-6 raciones al día Incrementar formas integrales	60-80g de pasta, arroz 40-60 g de pan 150-200 g de patatas	5
Verduras y hortalizas	≥ 2 raciones al día	150-200 g	4
Frutas	≥ 3 raciones al día	120-200 g	4
Aceite de oliva	3-6 raciones al día	10 ml	4
Leche y derivados	2-4 raciones al día	200-250 ml de leche 200-250 ml de yogur 40-60 g de queso curado 80-125 g de queso fresco	3
Pescados	3-4 raciones a la semana	125-150 g	3
Carnes magras, aves y huevos	3-4 raciones de cada a la semana. Alternar su consumo	100-125 g	3
Legumbres	2-4 raciones a la semana	60-80 g	3
Frutos secos	3-7 raciones a la semana	20-30 g	3
Embutidos y carnes grasas	Ocasional y moderado	-	2
Dulces, snacks, refrescos	Ocasional y moderado	-	1
Mantequilla, margarina y bollería	Ocasional y moderado	-	1

nutricionales sin tener en cuenta otros factores como sus limitaciones personales, la situación socioeconómica, la tradición o la cultura [4]. Particularmente, algunos estudios se centran en sistemas de recomendación basados en **lógica difusa**: en [71], el sistema es capaz de crear planes de alimentación en base a los **requerimientos individuales** (como la edad, el sexo o el BMI) a niveles de micro y macro nutrientes para personas que padecen **diabetes**. Además, tiene la habilidad de recomendar diversas dietas que incluyen todos los grupos alimentarios y que tiene en cuenta las necesidades médicas y sociales de cada persona. En otro estudio vinculado a la lógica difusa y centrado en pacientes con diabetes, se propone un sistema que determina la dieta del individuo a partir de su estado de salud. Para ello, la persona tiene que portar una serie de **dispositivos IoT** que monitorizan el cuerpo y que son almacenados en todo momento [72].

La alimentación saludable es uno de los aspectos más críticos en la sociedad, especialmente para las personas de **menor edad**: con una dieta sana, un niño puede aumentar la capacidad de aprendizaje, el comportamiento y en definitiva, llevar una vida mejor. A raíz de ello, *Hazman et al.* han propuesto un **sistema de nutrición para niños** que genera comidas saludables y que se rige por la edad, la etapa de crecimiento, el género o su estado saludable, entre otros [73]. En el extremo opuesto se encuentran las personas con **edad avanzada**, las cuales tienen dificultades a la hora de preparar dietas sanas o escoger los alimentos adecuados. Al mismo tiempo, estudios demuestran que este grupo de la población se alimenta de manera irregular, ocasionándoles **problemas** de salud y sociales. Por esta razón, se han presentado **sistemas de recomendación integrado en móviles y plataformas web** adaptado para personas en este rango de edad. *SousChef*, en primer lugar, es un sistema de recomendación que genera comidas personalizadas a partir de la información que facilita el usuario, incluyendo medidas antropométricas, preferencias

personales y actividades físicas del usuario (a partir de dispositivos inteligentes). Los consejos personales, así como la plataforma, está diseñada para personas ancianas, por lo que sigue unas recomendaciones de un nutricionista a la vez que proporcionan un entorno intuitivo para el usuario [74]. No obstante, no es el único estudio que se ha centrado en este perfil social: *NutElCare*, por otra parte, es un sistema de recomendación semántico que ha sido desarrollado bajo la supervisión de expertos en nutrición y gerontología y que facilita a personas mayores a consumir de una manera más saludable [75].

La **desinformación nutricional** que existe en la sociedad puede ser perjudicial para cada persona, sobre todo si esta realiza algún tipo de ejercicio físico de alta intensidad. Por eso, *Tummark et al.* han desarrollado un entorno capaz de recomendar dietas personalizadas en **personas deportistas**, por lo que la cantidad y composición de cada comida va determinado por el deporte que se vaya a practicar en ese día. El entorno está compuesto por una ontología nutricional, una ontología de los alimentos, un perfil proporcionado por el atleta y las guías nutricionales que marcan las normas para deportistas [76]. Para concluir, en la actualidad existen numerosas aplicaciones móviles relacionadas con llevar un estilo de vida saludable y que han ganado popularidad en los últimos años. Muchas de ellas se centran en calcular la información nutricional y calórica a partir de los productos alimenticios que ingiere el usuario y junto con las características personales de cada uno (incluyendo actividad física), analizan la evolución de su dieta: ejemplos de ellos son las aplicaciones *MyFitnessPal*³, que cuenta con más de 10 millones de descargas en 2021); *FatSecret*⁴ y *MyRealFood*⁵, que cuentan con un plan dietético; o *Lifesum*⁶, que aparte de generar dietas saludables es capaz de analizar y estimar las calorías de un alimento a partir de una imagen. No obstante, hasta ahora ningún estudio aporta una evaluación de la dieta de la persona, por lo que no ofrecen la posibilidad de analizar la calidad de lo que ingiere.

2.4. Conclusiones

En este capítulo se ha analizado el Estado del Arte del denominado *food computing* y de los hábitos saludables que recomiendan llevar algunas de las organizaciones más importantes a nivel global y nacional. Gracias a los avances tecnológicos, se han implementado herramientas usadas en diversos campos y como resultado, se han sustituido las recomendaciones (que hasta ahora iban dirigidas a grandes grupos poblacionales) por soluciones más personalizadas, atendiendo a las propias características de la persona y a otros factores indirectos.

Sin embargo, estas soluciones aún siguen siendo pioneras y no se han integrado en la sociedad, por lo que se requiere de más estudios que planteen este tipo de problemas. Es por ello que una de las posibles medidas recaiga en analizar la dieta de una persona y evaluar si está llevando una alimentación saludable o no. De esta manera, numerosos estudios se centran en clasificar el tipo de comida que una persona ingiere y como se ha detallado, los métodos que se han utilizado han logrado rendimientos muy prometedores (muchos de ellos por encima del 90%). Por estos motivos, el presente TFM se centra en la **implementación de un entorno que permita, de forma automática y programable, la creación de bases de datos sintéticas que reflejen distintos tipos de perfiles de hábitos de comportamiento alimenticio**. Para ello, será necesario generar previamente una base de datos de imágenes de alimentos de tal magnitud que permita identificar cualquier comida y que la categorice según lo saludable sea el alimento en cuestión.

³<https://www.myfitnesspal.com>

⁴<https://www.fatsecret.com/>

⁵<https://myrealfood.app/>

⁶<https://lifesum.com/>

3

Base de Datos de Alimentos y Grupos Alimentarios

En este capítulo se describe el procedimiento que se ha llevado a cabo para la creación de una base de datos de imágenes de alimentos a partir de otras bases de datos existentes en el Estado del Arte. En esta base de datos se tienen en cuenta los diferentes **grupos de alimentos** y niveles indicados en el Estado del Arte y por ello, cada producto está asociado con una categoría que lo encuadra en cada uno de ellos. De esta manera, la base de datos propuesta tiene un **valor fundamental** a la hora de crear el entorno programable, ya que la base de datos sintética que se genera se fundamenta en esta mediante las **imágenes** y las **características** de cada uno de los **productos**. En las siguientes secciones se explica de manera íntegra cada uno de los pasos realizados: **i) selección de bases de datos** y **ii) categorización**.

3.1. Selección de Bases de Datos

En una primera fase, se han seleccionado un total de 7 bases de datos teniendo en cuenta las diferencias que hay entre ellas, como la región, el número de imágenes y categorías o el escenario. En ese mismo contexto, el objetivo reside en generar un **conjunto de datos realista** (idealmente donde se muestren imágenes de platos de comidas), por lo que se van a necesitar alimentos de **todos los grupos alimentarios** descritos en la Sección 2.3.1. En la Tabla 3.1 se enumeran cada una de las bases de datos escogidas.

3.1.1. *UECFood-256*

UECFood-256 es una base de datos utilizada en numerosos estudios y cuenta con un total de **256 productos** mayoritariamente **japoneses**, aunque también cuenta con otros de carácter asiático e internacional. Las imágenes se han extraído a partir de diferentes *Application Programming Interface* (API) como *Bing Image Search*, *Flickr* o *Twitter*. Además, ha seguido un protocolo de selección mediante la plataforma de *crowd-sourcing Amazon Mechanical Turk* (AMT) [18]. Entre las más de 30.000 imágenes que posee, destacan imágenes de noodle, productos dulces o carnes¹.

¹<http://foodcam.mobi/dataset256.html>

Tabla 3.1: Bases de datos alimentos que han sido seleccionadas para el presente estudio. Para cada una, se describe el número de imágenes y categorías de alimentos, la región donde se encuentran los productos y el año de publicación. Se muestra también el enlace de descarga de cada una de ellas.

Base de Datos	Categorías/Imágenes	Región	Año
UECFood-256 ¹ [18]	256 / 31.395	Japón	2014
Food-101 ² [19]	101 / 101.000	Occidente	2014
Food-11 ³ [30]	11 / 16.643	Misc.	2016
FruitVeg-81 ⁴ [32]	81 / 15.737	Misc.	2017
MAfood-121 ⁵ [6]	121 / 21.175	Misc.	2019
ISIA Food-500 ⁶ [48]	500 / 399.726	Misc.	2020
VIPER-FoodNet ⁷ [12]	82 / 17.881	EE.UU.	2020

¹<http://foodcam.mobi/dataset256.html> ²https://data.vision.ee.ethz.ch/cvl/datasets_extra/food-101/
³<https://www.kaggle.com/vermaavi/food11> ⁴<https://www.tugraz.at/institute/icg/research/team-bischof/lrs/downloads/fruitveg81/>
⁵<http://www.ub.edu/cvub/mafood121/> ⁶<http://123.57.42.89/FoodComputing-Dataset/ISIA-Food500.html>
⁷[https://lorenz.ecn.purdue.edu/~sim\\$vn/](https://lorenz.ecn.purdue.edu/~sim$vn/)

3.1.2. Food-101

Food-101 es una de las primeras bases de datos publicada que suma más de **100.000 imágenes** de comida de todas partes del mundo [19]. Para ello, eligieron las 101 comidas más populares, recolectando un total de 1.000 imágenes por producto y extrayendo este contenido de la plataforma **FoodSpotting** (hoy en día ya cerrada). Tortilla, tarta de manzana o paella son algunos ejemplos de las comidas que se encuentran en este conjunto de datos².

3.1.3. Food-11

Los creadores de la base de datos **Food-11** decidieron estudiar el tipo de comida que la gente consume a diario para generar un conjunto de imágenes acorde al análisis [30]. De este modo, tuvieron en cuenta las **11 categorías de alimentos** definidas por el Departamento de Agricultura de Estados Unidos (USDA): pan, lácteos, postres, huevos, comida frita, carne, noodle/pasta, arroz, pescado, sopa y vegetales/frutas. Para ello, las **16.643 imágenes** se recolectaron de **3 bases de datos** ya existentes (*Food-101*, *UECFood-100* y *UECFood-256*) y de **2 plataformas sociales**: *Flickr* e *Instagram*³.

3.1.4. FruitVeg-81

Para compensar la falta de productos relacionados con las frutas y verduras, se ha añadido la base de datos *FruitVeg-81*, la cual contiene **81 variedades** de 53 productos diferentes y **más de 15.000 imágenes** [32]. Como se ha comentado previamente, la recolección de las imágenes se ha llevado a cabo en diferentes tiendas *SPAR* y con distintos teléfonos móviles, por lo que esta base de datos es la única de las seleccionadas que se han obtenido a partir de la técnica *Self-Collected*⁴.

²https://data.vision.ee.ethz.ch/cvl/datasets_extra/food-101/

³<https://www.kaggle.com/vermaavi/food11>

⁴<https://www.tugraz.at/institute/icg/research/team-bischof/lrs/downloads/fruitveg81/>

3.1.5. *MAFood-121*

Otra base de datos que se ha formado a partir de otras ya existentes (mediante la técnica **combinación**) es *MAFood-121*, la cual cuenta con 21.175 imágenes y **121 categorías**, incluyendo comidas de las **11 cocinas más populares del mundo** según *Google Trends* [6]. Estos 121 productos, además, pertenecen a una de las 10 categorías principales: pan, huevos, comida frita, carne, noodles/pasta, arroz, pescado, sopa, dumpling y vegetales. Al comparar estas categorías principales con las descritas en *Food-11*, se observa una similitud entre ambas. Con referencia a las bases de datos donde se han extraído las imágenes, **3** de ellas son **públicas** (*Food-101*, *UECFood-256* y *TurkishFoods-15*), mientras que la restante es **privada** (creada a partir del motor de búsqueda de *Google*)⁵.

3.1.6. *ISIA Food-500*

Con cerca de **400.000 imágenes** repartidas en 500 categorías se encuentra la base de datos *ISIA Food-500* [48]. Publicada en 2020, las diferentes imágenes se descargaron a partir de los motores de búsqueda de *Google*, *Baidu* y *Bing* y posteriormente, se realizaron tareas de limpieza y preprocesamiento. Este conjunto de datos aporta un mayor alcance en términos de categorías de alimentos, a la vez que genera una mayor diversidad: entre los 500 productos se hallan productos de todas partes del mundo, incluyendo las **cocinas orientales y occidentales**. Además, todos sus productos se encuentran dentro de las siguientes **11 categorías**: carne, cereales, vegetales, pescado, frutas, lácteos, productos horneados, grasas, pastelería, bebidas y huevos⁶.

3.1.7. *VIPER-FoodNet*

Finalmente, *VIPER-FoodNet* es una base de datos en donde las **17.881 imágenes** que la componen se han extraído a partir de *Google Image*. Las **82 categorías** se han seleccionado a través de un estudio realizado por *What We Eat In America (WWEIA)*, en el cual se analizan la frecuencia de consumo de los productos más populares en **Estados Unidos**⁷ [12].

Tras un análisis de cada una de las bases de datos seleccionadas, la suma total de **productos** asciende a **1.152**, obteniendo un total de **603.557 imágenes**. El siguiente paso, por tanto, reside en categorizar cada uno de estos productos en grupos más generales de alimentos.

3.2. Categorización

En esta sección se describe el procedimiento que se ha utilizado para categorizar cada uno de los más de 1.100 productos seleccionados. A cada producto se le ha asignado una **categoría principal** y una **subcategoría** de acuerdo a los criterios que se han establecido previamente (Sección 3.2.1). Además, las distintas categorías y subcategorías se han creado de cara a dar **soporte al entorno programable de creación de bases de datos sintéticas**, por lo que la categorización se ha planteado en base a los distintos grupos alimentarios y a las respectivas características que indican su frecuencia de consumo. Para cada subcategoría, se han incluido el **grado de ingesta** (que indica el nivel de frecuencia de consumo de los productos que lo forman) y el **tipo de plato** (esto es, si pertenece a plato principal, entrantes, etc.). Finalmente, para cada producto se le ha asignado la **región principal** de cada uno de ellos.

⁵<http://www.ub.edu/cvub/mafood121/>

⁶<http://123.57.42.89/FoodComputing-Dataset/ISIA-Food500.html>

⁷<https://lorenz.ecn.purdue.edu/~vfn/>

3.2.1. Clasificación por Categorías y Subcategorías

A continuación, se detalla el proceso que se ha realizado de cara a clasificar cada producto en una categoría principal y en una categoría secundaria. Tras una primera etapa donde se reconoce el tipo de comida y otras características, se ha llevado a cabo un proceso de control, donde finalmente se han obtenido las categorías finales.

Primera Etapa - Proceso de Categorización

Como se ha detallado anteriormente, algunas de las bases de datos escogidas (tal como *ISIA Food-500* o *UECFood-256*) se han creado a partir de una selección previa de los grupos de alimentos más comunes (como pan, verduras o pasta, entre otros). *Food-11*, por otro lado, ha decidido agrupar los productos sin tener en cuenta las diferencias que tienen entre sí, por lo que en las 11 categorías que consideran los autores, se encuentran alimentos totalmente diferentes entre sí, pero que comparten la categoría principal. Un ejemplo de ello es la categoría postres: en este caso, se muestran imágenes de productos que pertenecen tanto a bollería general como postres lácteos, por lo que se tratan a todos los productos como una clase principal.

Aparte, con el fin de obtener unas referencias sobre posibles **categorías alimentarias** que se puedan incluir en esta base de datos, se han extraído los principales grupos alimentarios de las bases de datos *ISIA Food-500*, *Food-11*, *MAFood-121* y los grupos de alimentos que se detallan en los estudios ofrecidos por la SENC (véase Figura 2.6 y Tabla 2.3). Atendiendo a los criterios expuestos, en este trabajo se han realizado **tres tareas** con el fin de etiquetar la categoría principal y secundaria de cada producto.

- En primer lugar, se ha obtenido el tipo de alimento que es basado en **ontologías de los alimentos**. En este caso, se ha utilizado la ontología *FoodOn*, la cual permite extraer la taxonomía del producto [77]. Por ejemplo, al realizar la búsqueda «macarrones» (*macaroni* en inglés), aparece una serie de resultados. Tras escoger el más acorde a él (*macaroni pasta*), se muestra un árbol en el que permite conocer su jerarquía: *macaroni pasta* pertenece a los productos de los macarrones (*macaroni food product*). A su vez, este pertenece al grupo *pasta food product* y así sucesivamente hasta llegar a uno de los grupos principales: producto alimenticio (*food product*). Por otro lado, esta ontología también muestra los subtipos que derivan del producto: siguiendo con el ejemplo, alguno de los subtipos que aparecen son productos similares como macarrones al estilo oriental o con otro tipo de formas⁸.
- Sin embargo, muchos de los productos que conforman las bases de datos no están contemplados por la ontología descrita, bien porque el producto es típico de una región muy concreta (como es el *takoyaki*, una comida típica de Japón), porque el nombre del producto es una descripción del mismo (carne en salsa de ostras) o incluso porque es una comida compuesta por varios alimentos (comida mixta). Por esta razón, en segundo lugar, se ha realizado una búsqueda a través de la plataforma web *TasteAtlas*⁹, la cual aloja una enciclopedia con más de 10.000 comidas tradicionales y una amplia variedad de ingredientes de todo el mundo. Además de indicar en su gran mayoría los ingredientes, aparece el tipo de comida que es (*snack*, plato principal, etc.) y el lugar de origen del producto. En este caso, *takoyaki* es un *snack* procedente de Osaka (Japón) y está hecho principalmente de huevos y harina.
- Aunque esta segunda tarea lidia con un gran porcentaje de los productos, sigue sin contemplar muchos otros (como el caso de aquellos productos con más de un alimento). Como

⁸<https://www.ebi.ac.uk/ols/ontologies/foodon>

⁹<https://www.tasteatlas.com/>

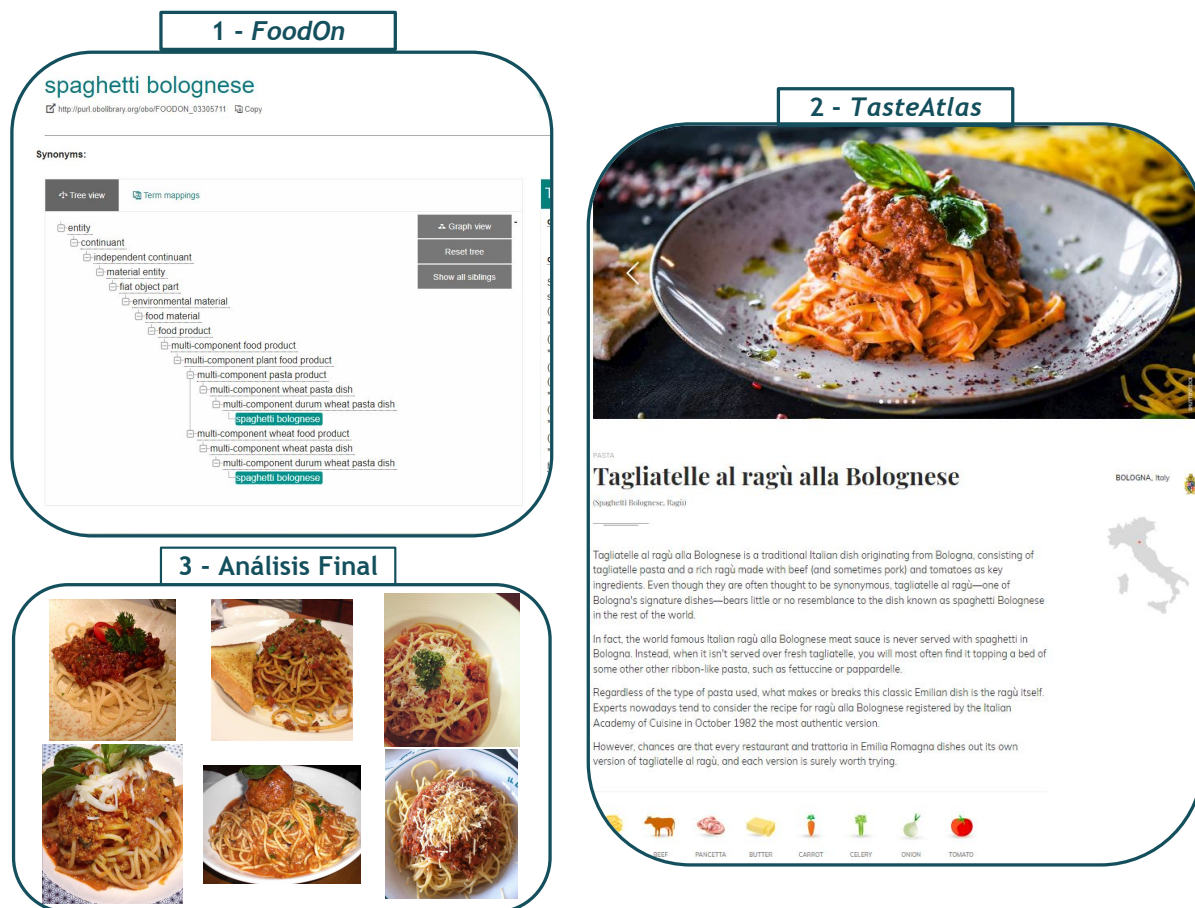


Figura 3.1: Proceso de categorización de los productos. En este caso, se ha tomado como ejemplo el producto «espaguetis a la boloñesa».

última tarea, se analizan las imágenes de cada uno de los productos y se extraen los alimentos que lo forman. Posteriormente, se le asigna una categoría principal y una subcategoría.

Como muestra de ello, a continuación se describe el procedimiento de búsqueda de categoría y subcategoría para el producto «**espaguetis a la boloñesa**» (en inglés *spaghetti bolognese*). Dicho procedimiento se muestra reflejado en la Figura 3.1: al buscar este producto en *FoodOn*, nos aparece que es un plato de **pasta multicomponente**, ya que lleva una salsa acompañada. Por otro lado, al realizar la búsqueda en *TasteAtlas*, nos aparece como un plato de **pasta italiano** que lleva ingredientes como la propia pasta, carne y algunos vegetales. Tras analizar las imágenes de este producto, se puede considerar como un producto cuya categoría principal es «**Noodle y Pasta**», y la categoría secundaria es «**Pasta Italiana**». También hay que destacar que aunque sea un producto de origen italiano, su popularidad ha hecho que este alimento se considere de carácter internacional. En la Tabla 3.2 (se encuentra al final de este Capítulo) se detalla cada una de las **categorías** y **subcategorías** que componen la **base de datos de alimentos y grupos alimentarios propuesta**.

Segunda Etapa - Proceso de Control

Usando un procedimiento similar al realizado con los «espaguetis a la boloñesa», se han categorizado los más de **1.100 productos** de cada base de datos y posteriormente, se ha realizado un proceso de **revisión** y **unificación**. Este proceso se encarga: por un lado, de comprobar

que todos los productos se han **categorizado correctamente** y además, de **eliminar** aquellos productos que **no se adecuan** a los criterios establecidos; por otro lado, de **agrupar** categorías y subcategorías que sean muy similares entre sí. De esta manera, el número de grupos se reduce y se estructura de una forma más organizada. Por ejemplo, las categorías «**Noodle y Pasta**», que se encontraban separadas, se han unificado en una única debido a que las imágenes observadas entre ambas, comparten características como la forma en la que los platos se muestran, los acompañantes de estos alimentos o la manera en la que se ha fotografiado cada uno de los productos, entre otros.

Como resultado final, de los 1.152 productos que se han analizado, han permanecido **912 productos finales** tras realizar los procesos descritos y la suma total de imágenes alcanza las **579.540**. Por otro lado, estas comidas se han repartido en un total de **19 categorías y 72 subcategorías**, tal y como se muestra en la Tabla 3.2 (al final del capítulo). En ella destacan algunas categorías generales que se han observado en previas bases de datos como «**Arroz**», «**Noodle y Pasta**», «**Frutas**», «**Pescado**» o «**Huevos**», entre otros muchos. Además, en algunas categorías como «**Carne y Derivados**», está compuesta por más de un subtipo: en este caso, se divide en «**Carne Blanca**», «**Carne Roja**», «**Carne Mixta**», «**Carne Empanada**», «**Salchicha**» y «**Paté**». Otro ejemplo de ello es «**Fast Food**», el cual se compone de «**Pizza**», «**Hamburguesa**», «**Hot Dog**» y «**Patatas Fritas**». Esta división se debe a que, además de las **grandes diferencias visuales** que se observan entre los productos, algunas de las subcategorías se encuentran en un **grupo alimentario o grado de ingesta diferente** (este tipo de clasificación se detalla en la Sección), por lo que una división en esta fase mejorará considerablemente la calidad de la base de datos sintética.

En último lugar, a cada producto se le ha asignado una región en base a su procedencia y consumo, contabilizando **6 regiones específicas** (norteamérica, latino américa y el caribe, europa, áfrica y oeste de asia, asia central, y este y sudeste de asia) y **1 región general** (denominado internacional), en la que esta última se asocia a productos que son consumidos en todo el mundo (como pizza, pasta o hamburguesa).

Por otra parte, cabe destacar la categoría «**Comida Mixta**», la cual está formada por más de un alimento. Esta distinción se ha realizado debido a que en muchos de los productos analizados, se ha observado una composición de más de un alimento en proporciones de cantidad similares. Por ejemplo, en la subcategoría «**Arroz y Carne**», los productos que lo forman (como *katsudon* o *vindaloo*) están constituidos tanto de arroz como de carne en cantidades muy parecidas, por lo que se diferencia claramente de las categorías «**Arroz**» y «**Carne y Derivados**». Otra de las razones se debe a que en muchos de los alimentos se utilizan ingredientes muy variados y diferentes, por lo que en cada imagen pueden aparecer de una manera distinta. Ejemplos de ello son las subcategorías «**Dumpling Asiático**», «**Sushi**», «**Empanada**» o «**Masa Rellena**». Finalmente, se ha creado una categoría especial para las **bebidas**, las cuales se encuentran en la mayoría de las comidas. En ella se pueden diferenciar 5 subtipos: «**Bebidas Vegetales**», «**Café**», «**Bebidas Azucaradas**», «**Bebidas Alcohólicas**» y «**Otras Bebidas**». En la Figura 3.2, se muestran algunos ejemplos de imágenes de productos pertenecientes a las distintas categorías y subcategorías definidas.

3.2.2. Otros Tipos de Clasificación

Además de la clasificación por categorías y subcategorías, los productos se han clasificado según el grado de sostenibilidad y el tipo de plato a nivel de subcategoría, por lo que las comidas de una misma subcategoría tendrán los mismos valores (debido a la similitud que comparten). Por un lado, el **grado de ingesta** indica el nivel de frecuencia con la que ha de ser ingerido un producto. Por otro lado, el **tipo de plato** se asocia a la cantidad de comida de un alimento.



Figura 3.2: Ejemplos de algunas imágenes de productos que se encuentran en la base de datos generada. Se han dividido por categorías y subcategorías.

Este tipo de clasificaciones, por tanto, sirven para la creación de diferentes perfiles de hábitos alimentarios que se explica en el Capítulo 4.

Grado de Ingesta

Los diferentes niveles que se observan en la pirámide nutricional (véase Figura 2.6), señalan la frecuencia de consumo de un determinado grupo alimentario: para aquellos que se encuentran en niveles más altos (del 3 al 5), su frecuencia tiene que ser diaria en base a las recomendaciones que aconsejan, y los de menor nivel (1 y 2), la frecuencia es semanal debido a que pertenecen a grupos de consumo opcional y moderado. Teniendo en cuenta las características de la base de datos que se ha generado en este estudio, muchas de las subcategorías ya están relacionadas con uno de estos grupos alimentarios y, por tanto, están asignados en un grado de sostenibilidad. Un ejemplo de ello son los «**Productos Dulces**» (emplazados en el nivel 1) o el «**Arroz**» y la «**Pasta Italiana**» (los cuales se encuentran en el nivel 5).

Sin embargo, numerosas subcategorías no se ven reflejadas en esta pirámide, y por ello se le debe asignar un nivel acorde a los productos que la componen. En consecuencia, se ha creado un tipo de clasificación basado en el **grado de ingesta** que, de manera similar al grado de sostenibilidad, su grado indica la frecuencia de consumo de un determinado grupo de alimentos: cuanto mayor grado de ingesta tenga un grupo, mayor debe ser la frecuencia de consumo y al contrario; cuanto menor sea el grado (excepto el 0), menor debe ser la frecuencia de consumo. En consecuencia, se han definido **7 grados de ingesta**.

Por otra parte, se han encontrado **dos escenarios** en los cuales los productos **no se adecuan a los grados establecidos**: por un lado, la leche, los frutos secos o el aceite de oliva (productos únicos definidos en la pirámide nutricional - Figura 2.6) no se encuentran como productos independientes, por lo que su presencia es nula; por otro lado, las patatas y legumbres tiernas tampoco se han encontrado como productos únicos, pero sí se hallan en otros grupos alimentarios, por lo que se les ha añadido a sus productos homólogos. A continuación, se describe la asignación final de cada una de las subcategorías, la cual se muestra en la Tabla 3.2 (al final de este Capítulo):

- **Grado 0**: este grado no contempla la frecuencia de consumo debido a que los productos que se encuentran en él no se han considerado en los grupos alimentarios (a excepción del pan). Por un lado, se encuentran productos que no están preparados para tomarse (como «**Hortalizas Frescas**» «**Legumbres Frescas**») o no han sido catalogados como tal («**Café**» y «**Bebidas Alcohólicas**»). Por otro lado, se ha realizado un tratamiento especial a la subcategoría «**Pan**», ya que su ingesta se realiza en la mayoría de las comidas.
- **Grado 1**: análogo al nivel 1 de sostenibilidad, este grado está compuesto por productos de consumo muy opcional y moderado, con una frecuencia semanal muy baja. Entre las categorías principales se encuentran los «**Snack Salados**», los «**Productos Dulces**» y «**Fast Food**» y también se componen de algunas subcategorías como el «**Paté**» (grasa untable), las «**Salsas**» y «**Bebida Azucaradas**».
- **Grado 2**: en este grado, el consumo pasa a tener un poco de mayor frecuencia, pero sigue siendo un consumo moderado y opcional. El nivel 2 de sostenibilidad de la pirámide es el análogo de este grado, en donde destacan aquellos productos de origen animal que pertenecen a carnes rojas, procesadas y embutidos. En este estudio, todas las carnes (excepto «**Carnes Blancas**» y el «**Paté**») se encuentran en este grado, además de otros productos como toda la «**Comida Frita**», el «**Dumpling Asiático**», la «**Empanada**», la «**Masa Rellena**», las «**Bebidas Vegetales**» (normalmente tienen un alto contenido en azúcar) y la categoría «**Sandwich**».

- **Grado 3:** este grado corresponde con una frecuencia de **consumo variable**, ya que los productos que forman parte no se le pueden emplazar como de consumo diario ni como de consumo opcional. Este grado cuenta con las subcategorías de «**Pan y Productos Similares**» (excepto el tipo «**Pan**»), la subcategoría «**Comida Mixta**» (con más de 50 productos) y la subcategoría «**Arroz y Carne**».
- **Grado 4:** este grado corresponde con el nivel 3 de la pirámide nutricional, por lo que incluye categorías y subcategorías como «**Lácteos**», «**Pescados**», «**Carnes Blancas**», «**Marisco**», «**Legumbre Cocinada**», «**Huevos**», «**Platos de Cuchara**» y algunos subtipos de «**Comida Mixta**».
- **Grado 5:** coincidiendo con el nivel 4 de la pirámide, se encuentran las categorías de «**Frutas**» y «**Ensalada**» y las subcategorías de «**Hortalizas Cocinadas**» y «**Vegetales y Hortalizas**» (esta última perteneciente a la categoría «**Comida Mixta**»).
- **Grado 6:** el último nivel y por tanto, el de mayor frecuencia de consumo se equipara con el nivel 5 de la pirámide. En este caso, las categorías «**Arroz**» (y su subcategoría en «**Comida Mixta**») y «**Noodle y Pasta**» son las que componen este nivel, aunque la recomendación indica que estos productos sean consumidos en su forma integral o de grano entero.

Tipo de Plato

Además de definir cómo de saludable es un producto, es importante diferenciar entre los diferentes **tipos de platos** o tiempos de una comida que existen. Dependiendo de cuándo se realice una comida, esta puede estar formada por un número indeterminado de platos. Mientras que una comida a mediodía puede estar formada normalmente por entre 3 y 5 platos (aperitivo, primer y segundo plato, entremés y postre), un desayuno, en líneas generales, es de un plato único (en algunas ocasiones más de uno)¹⁰. En este estudio se ha tenido en cuenta los **diferentes tipos de platos** de cara a la desarrollo del entorno programable de creación de bases de datos sintéticas (véase Capítulo 4), por lo que a cada una de las subcategorías se le ha asignado un tipo de plato correspondiente, tal y como se detalla en la Tabla 3.2 (al final del capítulo).

En este caso, el criterio utilizado ha dependido exclusivamente de la subcategoría a la que pertenece el producto, atendiendo a los siguientes tipos de platos:

- **Plato Principal:** este plato constituye normalmente el primer o segundo plato de una comida. Teniendo en cuenta las subcategorías que se han creado, un alto porcentaje pertenecen a este tipo de plato.
- **Aperitivo:** es una comida con menor densidad y que usualmente se toma antes de un plato principal. En este caso, los aperitivos que se han escogido han sido el «**Queso**», el «**Paté**» y «**Otros Tipos de Pan**» (pan con algún ingrediente ligero en el interior).
- **Snack:** este tipo de plato son parecidos a los aperitivos pero con una densidad incluso menor a estos últimos. Este grupo lo forman los «**Snack Salados**» y la subcategoría «**Salsa**» (la cual es normalmente acompañada por pan o por otro *snack*).
- **Postres:** los postres se suelen tomar en el desayuno, merienda o al final de una comida principal. Las «**Frutas**», la «**Tostada**», el «**Yogurt**» y todos los «**Productos Dulces**» componen este tipo de plato.

¹⁰<https://www.webstaurantstore.com/blog/2578/full-course-meal.html>

- **Acompañamiento:** el acompañamiento, como su nombre indica, acompaña a los platos principales. En este estudio se han tenido en cuenta únicamente la «**Ensalada**» y las «**Patatas Fritas**».
- **Pan:** es un alimento básico que se suele tomar con los platos principales. Se ha decidido diferenciarlo con el acompañamiento por cuestiones asociadas a la creación de la base de datos sintética (véase Capítulo 4). Por lo tanto, la única subcategoría que aparece es el «**Pan**».
- **Bebidas:** el último tipo de plato son las «**Bebidas**», en las que se han incluido todas ellas.

Como se ha comentado a lo largo de este capítulo, el objetivo de esta clasificación es **dar soporte al entorno de creación de bases de datos sintéticas** (véase Capítulo 4). Por ello, los tipos de platos se han agrupado a su vez en **5 grupos** en base a su **densidad**, como se detalla a continuación:

- **Grupo 1:** plato principal.
- **Grupo 2:** aperitivo, *snack* y postres.
- **Grupo 3:** acompañamiento.
- **Grupo 4:** pan.
- **Grupo 5:** bebidas.

Tabla 3.2: Categorías y subcategorías definidas en la base de datos propuesta.

Categoría Principal	Subcategoría	Productos Finales	Grado de Ingesta.	Tipo de Plato
Arroz	Arroz	14	6	Principal
Noodle	Noodle	58	6	Principal
y	Pasta Italiana	14	6	Principal
Pasta	Otros Tipos de Pasta	4	6	Principal
Vegetales y Hortalizas	Hortaliza Fresca	20	0	-
	Hongos	2	0	-
	Hortaliza Cocinada	14	5	Principal
	Hortaliza Frita	12	5	Principal
Frutas	Frutas	29	5	Postres
Carne y Derivados	Carne Blanca	15	4	Principal
	Carne Roja	28	2	Principal
	Carne Mixta	23	2	Principal
	Carne Empanada	17	2	Principal
	Salchicha	2	2	Principal
	Paté	1	1	Aperitivo
Pescado	Pescado Variado	20	4	Principal
	Pescado Empanado	7	2	Principal
Marisco	Molusco	6	4	Principal
	Crustáceo	5	4	Principal
	Marisco Frito	3	2	Principal
	Marisco Variado	1	4	Principal
Legumbres	Legumbre Fresca	1	0	-
	Legumbre Cocinada	11	4	Principal
	Legumbre Frita	2	2	Principal
Huevos	Huevos	7	4	Principal
Lácteos	Queso	1	4	Postres
	Yogurt	1	4	Aperitivo
	Lácteos Fritos	2	2	Principal
Ensalada	Ensalada	22	5	Acompañamiento
Platos de Cuchara	Sopas y Cremas	63	4	Principal
	Guisos y Estofados	22	4	Principal
Pan y Productos Similares	Pan	4	0	Pan
	Tostada	7	3	Postres
	Otros Tipos de Pan	5	3	Aperitivo
Sandwich	Sandwich	21	2	Principal
	Wrap	8	2	Principal
<i>Snack</i> Salados	Frutos Secos	2	1	<i>Snack</i>
	Hortalizas y Verduras	3	1	<i>Snack</i>
	Legumbres	3	1	<i>Snack</i>
	Otros <i>Snack</i> Salados	2	1	<i>Snack</i>
Productos Dulces	Bollería	95	1	Postres
	Chocolate y Derivados	6	1	Postres
	Postres Lácteos	14	1	Postres
	Dulces de Frutas	9	1	Postres
	Otros Productos Dulces	16	1	Postres

Continuación de la Tabla 3.2

Categoría Principal	Subcategoría	Productos Finales	Grado de Ingesta.	Tipo de Plato
<i>Fast Food</i>	Pizza	6	1	Principal
	Hamburguesa	4	1	Principal
	<i>Hot Dog</i>	3	1	Principal
	Patatas Fritas	3	1	Acompañamiento
Comida Mixta	Arroz Mixto	22	6	1
	Arroz y Carne	15	3	Principal
	Arroz y Pescado	2	4	Principal
	Arroz y Legumbres	4	4	Principal
	Vegetales y Hortalizas	16	5	Principal
	Carne y Derivados	48	2	Principal
	Carne y Vegetales	20	4	Principal
	Pescado	9	4	Principal
	Marisco	15	4	Principal
	Legumbres Mixtas	7	4	Principal
	Huevos Mixtos	8	4	Principal
	Dumpling Asiático	10	2	Principal
	Sushi	5	4	Principal
	Empanada	3	2	Principal
	Masa Rellena	4	2	Principal
	Comida Frita	14	2	Principal
	Comida Mixta	54	3	Principal
Salsa	5	1	<i>Snack</i>	
Bebidas	Bebidas Vegetales	2	2	Bebida
	Café	2	0	Bebida
	Bebidas Azucaradas	3	1	Bebida
	Bebidas Alcohólicas	3	0	Bebida
	Otras Bebidas	3	1	Bebida

4

Hábitos de Comportamiento Alimenticio: Entorno Programable

En este Capítulo se explica en profundidad el **primer entorno programable** que se ha diseñado para la **generación de bases de datos sintéticas que reflejan los distintos tipos de perfiles de hábitos de comportamiento alimenticio**. El sistema implementado es capaz de generar dietas basadas en una serie de reglas y limitaciones impuestas por los diferentes perfiles creados. De esta manera, se convierte en la única base de datos que va a permitir analizar la salud a través de los hábitos alimenticios de una persona. Para ello, el procedimiento que se ha seguido consta de 3 procesos: **i) parametrización, ii) creación de los perfiles, y iii) creación de la base de datos sintética**. No obstante, al tratarse de un entorno programable y configurable, los **dos últimos procesos** pueden ser muy **distintos** ante la generación de nuevas bases de datos sintéticas, por lo que simplemente se ha mostrado un ejemplo de ello.

4.1. Parametrización

La parametrización es una manera de configurar, de manera automática, las diferentes dietas alimentarias que se van a generar. De esta manera, la calidad de una dieta depende de cómo se hayan ajustado los distintos parámetros atendiendo a las características de cada perfil. Estos parámetros, a su vez, se designan para poder establecer una serie de límites en cuanto al tipo de alimentos que se va a consumir y a otras características, como el número de comidas por días. Determinar, por tanto, cada uno de estos valores, se define exclusivamente por el tipo de perfil que se le ha asociado a cada usuario. En otras palabras, un perfil que se base en una alimentación sana va a tender hacia una dieta que tenga en cuenta las recomendaciones saludables que se han visto en el Estado del Arte (véase Sección 2.3.1).

Por ello, se han definido un total de **25 parámetros** que el sistema utiliza para la configuración de cada una de las dietas. Estos parámetros se dividen a su vez en 4 subtipos basados en: las **características de la dieta**, el **grupo alimentario**, el **grado de ingesta** y otros asociados al **pan y bebidas**.

Tabla 4.1: Parámetros asociados a las características de la dieta.

Nombre del Parámetro	Descripción	Valor [mín.,máx.]
dieta	Tipo de dieta	Sano, Insano o Medio
region	Región donde pertenece el usuario	Región del mundo
num_comidas	Número de comidas en un día	[1,5]
platos_principales	Número de platos principales en un día	[2,4]
platos_principales_comida	Número de platos principales en una comida	[1,3]
regularidad	Número de semanas en las que un usuario mantiene su dieta	[0,4]
perfil_objetivo	En caso de semana no regular, tipo de dieta	Sano, Insano o Medio

4.1.1. Parámetros Asociados a las Características de la Dieta

Según las recomendaciones de la SENC¹, la ingesta diaria se debe fraccionar entre **3 y 5 comidas** en horarios regulares. Aunque no se indica, estas comidas no tienen la misma proporción de cantidad (una merienda no se puede equiparar con una comida a mediodía), por lo que se ha de definir estos criterios: se ha determinado que entre **2 y 3 comidas** (comida, cena y en algunos casos desayuno) tengan un **peso mayor** que el resto (almuerzo, merienda) a la hora de definir el número de platos que se ingieren en cada comida. A raíz de ello, en la Sección 3.2.2 se ha determinado la cantidad de comida que se encuentra en cada producto y de este modo, se han agrupado en 5 grupos diferentes (1 - plato principal, 2 - aperitivo, *snack* y postres, 3 - acompañamiento, 4 - pan, y 5 - bebidas). Por lo tanto, las comidas de mayor peso tendrán al menos un producto del grupo 1 en cada una de ellas (esto es, un plato principal), limitando de igual manera el número máximo de productos de este grupo.

Todas estas serie de limitaciones y criterios se han tenido en cuenta para definir cada uno de los parámetros de este tipo, los cuales se muestran en la Tabla 4.1. En ella, también se muestran otros parámetros como el **tipo de dieta** (sano, insano o un balance entre estas dos -medio-), la **regularidad** con la que un perfil tiende a seguir una misma dieta o la **región** donde pertenece. Este último parámetro es crucial a la hora de seleccionar los productos que van a formar parte de la dieta, por lo que dependiendo de la zona asignada, se tendrán en cuenta los productos de esa región. Tras el análisis realizado en la Sección 3.2.1, se han detectado **6 regiones específicas** (norteamérica, latino américa y el caribe, europa, áfrica y oeste de asia, asia central, y este y sudeste de asia) y **1 general** (internacional). El parámetro «region», por tanto, puede estar asignado por uno de estos 7 valores, incluyendo uno adicional en el que no se tiene en cuenta la región, por lo que cualquier producto puede encontrarse en la dieta a independencia de este factor.

4.1.2. Parámetros Asociados al Grupo de Alimentos

Otro de los aspectos que se han tenido en cuenta a la hora de generar las diferentes dietas es el número de veces que se ingiere un producto correspondiente a los **12 grupos alimentarios**

¹<https://www.nutricioncomunitaria.org/es/>

Tabla 4.2: Parámetros asociados a los grupos alimentarios (tabla de la izquierda) y a los grados de ingesta (tabla de la derecha).

Grupos Alimentarios		Grado de Ingesta	
Nombre del Parámetro	Descripción	Nombre del Parámetro	Descripción
verduras	Número de verduras en un día	primer_nivel	Número de comidas de primer nivel por semana
frutas	Número de frutas en un día	segundo_nivel	Número de comidas de segundo nivel por semana
lacteos	Número de lacteos en un día	sexto_nivel	Número de comidas de sexto nivel por semana
pescado	Número de pescados en una semana		
carnes	Número de carnes en una semana		
huevos	Número de huevos en una semana		
legumbres	Número de legumbres en una semana		
carnes_grasas	Número de carnes grasas en una semana		

que aparecen en la Tabla 2.3. De estos 12 grupos, se han descartado 5 de ellos a causa de **dos razones**: la primera de ellas se debe a que en la base de datos de imágenes generada, no hay ninguna subcategoría que cubra algunos **grupos alimentarios** como el aceite de oliva o los frutos secos naturales; por otra parte, hay grupos en los que se ha tenido en cuenta el grado de ingesta al que pertenece, por lo que no se ha contemplado en este tipo. Ejemplos de ello es el grupo formado por patatas, arroz, pan, pan integral y pasta (el cual se considera como «sexto_nivel»).

Por lo tanto, hay un parámetro asociado para cada uno de los **8 grupos** finales, tal y como se detalla en la Tabla 4.2 (izquierda): «verduras», «frutas», «lacteos», «pescado», «carne», «huevos», «legumbres» y «carnes_grasas». A diferencia de los anteriores parámetros, estos son muy variables y dependen totalmente del perfil que se le asocie, por lo que su valor puede cambiar radicalmente entre un perfil y otro.

4.1.3. Parámetros Asociados al Grado de Ingesta

En este punto, ya se han definido algunos parámetros que cubren ciertos grupos de alimentos (como las verduras o los huevos). Sin embargo, **para compensar la falta de los grupos restantes**, se han determinado **parámetros asociados al grado de ingesta** al que pertenecen. De esta manera, todos los productos presentes en la base de datos (exceptos aquellos que no pueden ser consumidos y los definidos en el último subtipo) están asociados a algún parámetro definido. Tras un análisis, se ha detectado que en los niveles 1, 2 y 6, había productos que no estaban contemplados. Por lo tanto, se han definido un total de **3 parámetros** asociados al grado de ingesta, como se muestra en la Tabla 4.2 (derecha). Al igual que en los parámetros asociados al grupo alimentario, estos valores dependen de cada perfil, por lo que pueden ser muy diferentes entre sí.

Tabla 4.3: Parámetros asociados al pan y bebidas.

Nombre del Parámetro	Descripción	Nombre del Parámetro	Descripción
pan	Probabilidad de que el perfil coma pan	bebida	Probabilidad de que el perfil tome bebidas
cafe_semana	Número de días en los que toma café	cafe_dia	Número de cafés que toma al día
alcohol_semana	Número de días en los que toma alcohol	alcohol_dia	Número de veces que toma alcohol al día

4.1.4. Parámetros Asociados al Pan y Bebidas

Finalmente, se encuentran otros parámetros que generan un mayor realismo a la base de datos sintética: por un lado, indicando la probabilidad con la que el perfil **come pan** y toma diferentes **bebidas** disponibles (excepto café y alcohol); y por otro lado, la frecuencia con la que toma café y alcohol (2 parámetros por cada uno). Por lo tanto, un total de 6 parámetros se han utilizado, tal y como se detalla en la Tabla 4.3.

Estos parámetros se ajustan para generar una dieta de **28 días**, es decir, 4 semanas. El criterio se ha establecido de esta manera ya que las recomendaciones que aconsejan se basan en el consumo de alimentos por días (para los grupos de alimentos de mayor consumo) y semanas (para aquellos con menor peso).

4.2. Creación de los Perfiles

En esta sección se detalla cómo se han **generado** los distintos **perfiles** para construir la base de datos sintética. Para ello, se han seguido las recomendaciones saludables descritas en la Sección 2.3.1 y, en base a ellas, se han generado un total de **15 perfiles** diferentes con una dieta de 4 semanas (28 días) de duración. En esta fase, por tanto, es donde se realiza la asignación de valores para cada uno de los parámetros descritos anteriormente, por lo que cada perfil ha tenido un análisis independiente del resto. No obstante, todos ellos comparten la mayoría de los valores de los parámetros asociados a las características de la dieta, debido a que se ha querido mantener un número de comidas y platos parejos. A continuación, se detalla cada perfil generado (véase también en la Tabla 4.4):

- **Perfil 1:** este perfil denominado como **sano**, sigue las recomendaciones saludables comentadas anteriormente. De este modo, la gran mayoría de los productos que forman parte de esta dieta son aquellos que se encuentran entre los grados de ingesta 4 y 6, mientras que los que se encuentran entre el 1 y el 3 tendrán una menor probabilidad de aparecer. De igual manera ocurre con los productos de los grupos alimentarios que se recomiendan un consumo superior al resto. Por lo tanto, los valores de los parámetros se han definido en base a estos criterios y restricciones.
- **Perfil 2:** en el otro extremo se encuentra el perfil denominado como **insano**. Para ello, se ha tenido en cuenta un criterio totalmente opuesto al que se recomienda como una dieta saludable. En este caso, los productos que tienen una mayor probabilidad de aparecer son los que se encuentran en los grados de ingesta más bajos (1 al 3) y en menor medida, los que están en niveles superiores (del 4 al 6).

Tabla 4.4: Perfiles creados para la base de datos sintética.

Perfil	Descripción	Perfil	Descripción
1	Sano	2	Insano
3	Medio	4	Insano con tendencia a platos del primer nivel
5	Insano con tendencia al alcohol	6	Sano con tendencia al alcohol
7	Insano con poca ingesta de platos de los niveles más altos	8	Tendencia a un consumo excesivo de carne
9	Sano con consumo de platos de niveles bajos durante dos días	10	Sano con consumo alto de platos del nivel seis (deportista)
11	3 semanas perfil sano 1 semana perfil insano	12	2 semanas perfil sano 2 semanas perfil insano
13	1 semana perfil sano 3 semanas perfil insano	14	Perfil variable regular
15	Perfil variable irregular		

- **Perfil 3:** entre los dos perfiles anteriormente mencionados se encuentra un perfil **medio**. Como su nombre indica, es un promedio de ambos perfiles, por lo que habrá un equilibrio entre productos de mayor y menor grado de ingesta.
- **Perfil 4:** este perfil se ha basado en el segundo perfil, el cual se describe como **insano**. Además, se le ha aplicado un **peso mayor** a los productos del **primer grado de ingesta**, por lo que los productos de este grado aparecerán con mayor frecuencia que el resto.
- **Perfil 5:** es similar al **perfil 2** con la diferencia de que este tiene una **tendencia al consumo de alcohol**, por lo que el parámetro asociado con esta bebida tendrá una mayor frecuencia.
- **Perfil 6:** es similar al **perfil 1** con la diferencia de que este tiene una **tendencia al consumo de alcohol**, por lo que el parámetro asociado con esta bebida tendrá una mayor frecuencia.
- **Perfil 7:** basado en el perfil **insano**, tiene la característica de que el consumo de alimentos de los grados altos de ingesta (del 4 al 6) es prácticamente inexistente, por lo que este perfil tiende a un **consumo muy insalubre**.
- **Perfil 8:** es un perfil **medio** (perfil 3), con la diferencia de que el **consumo de carne** (tanto carne grasa como carne blanca) es **mucho mayor al recomendado**, por lo que todos los productos que contengan este grupo alimentario aparecerán con mayor frecuencia.
- **Perfil 9:** este perfil **sano** tiene la particularidad de tener un **mayor consumo** de productos pertenecientes a los grados de ingesta muy bajos (1 y 2) durante **dos días** a la semana, lo que simula a una persona que consume de manera saludable excepto en los fines de semana.
- **Perfil 10:** una persona con alta **actividad física** diaria necesita un aporte adicional de productos que se encuentren en el **grado 6 de ingesta**, mucho mayor que una persona con una vida más sedentaria. Por ello, este perfil de alimentación **sana** consumirá productos de este grado de ingesta con mayor frecuencia que otros perfiles corrientes.

- **Perfil 11:** la dieta de este perfil cuenta con **3 semanas** en las que tendrá una dieta **sana** y **una semana** con un perfil mucho más **insano**. Este tipo de perfil simula a personas que normalmente comen de manera saludable, pero que debido a ciertos eventos (como vacaciones o largos periodos fuera de casa), la alimentación se vuelve insana.
- **Perfil 12:** en este caso, el perfil tendrá **2 semanas** de dieta **saludable** y otras **2** de dieta **insalubre**. Este tipo de perfil simula a personas que normalmente comen de manera saludable, pero que debido a ciertos eventos (como vacaciones o largos periodos fuera de casa), la alimentación se vuelve insana.
- **Perfil 13:** similar al perfil 11 y 12, este perfil cuenta con **1 semana de dieta sana** y **3 semanas de dieta insana**.
- **Perfil 14:** este perfil **medio** tiene la particularidad de tener una **dieta variable**. En este sentido, las frecuencias de consumo de los grupos alimentarios, así como de los productos que se encuentran en los diferentes grados de ingesta, es muy **cambiante** a lo largo de las semanas. De esta manera, una semana puede estar consumiendo más alimentos de un cierto grupo alimentario y otra semana, su consumo podría disminuir o aumentar de manera considerable.
- **Perfil 15:** similar al perfil 14 con la diferencia de que este perfil parte de una dieta **sana**. Además, su **dieta puede cambiar** a lo largo de las semanas y y variar a una dieta más insana.

4.2.1. Asignación de Valores

Seguidamente, se tienen que **asignar una serie de valores** dentro de un rango para cada uno de los parámetros (Tablas 4.3 y 4.5). Los valores designados deben tener una **concordancia lógica** con la descripción del **perfil**. Además, para realizar esta tarea, se requiere un análisis desde un punto de vista tanto **general** (comparación entre perfiles) como **específico** (ajuste de los parámetros para cada perfil). Por otro lado, para que los usuarios de un mismo perfil tengan diferencias, el valor que se le asocie a cada parámetro va a ser generado **al azar**, dentro de un rango de valores que se asignen previamente a cada parámetro. Por lo tanto, para cada parámetro numérico (exceptuando los parámetros «pan» y «bebida»), habrá un valor mínimo y un valor máximo para que se cumpla este requisito. En este punto, **cada nueva base de datos sintética** tendrá una **configuración** diferente en términos de número de perfiles, usuarios, semanas y otras características en base a las preferencias que se le haya programado. En la Tabla 4.5 se muestran **5** ejemplos de algunos de los **perfiles** que se han propuesto en este TFM, indicando la asignación de valores de cada parámetro y considerando todas las limitaciones que se describen a continuación.

Parámetros Asociados a las Características de la Dieta

En la Tabla 4.1, se observa que los parámetros están bastante **delimitados** por una serie de valores. Para cada perfil, los valores siempre se van a encontrar dentro del rango previamente establecido, por lo que en este caso, los perfiles tendrán **características** con una **similitud alta** entre ellos. Con estas limitaciones, el número de comidas al día (menos de 5) y de platos principales por comida (menos de 4) se encuentra en unos valores racionales para cada perfil.

Tabla 4.5: Ejemplos de perfiles con sus respectivos parámetros. *s.s. semana sana, s.i. = semana insana.

Parámetro		Perfil 1	Perfil 2	Perfil 3	Perfil 11	Perfil 14
dieta		Sano	Insano	Medio	Sano	Medio
descripcion		Sano	Insano	Medio	3 s.s. 1 s.i.*	Perfil variable
region		-	-	-	-	-
num_comidas	Mín.	3	3	3	3	3
	Máx	5	5	5	5	5
platos_principales	Mín.	4	4	4	4	4
	Máx	5	5	5	5	5
platos_principales_comida	Mín.	2	2	2	2	2
	Máx	3	3	3	3	3
regularidad	Mín.	4	4	4	3	4
	Máx	4	4	4	3	4
perfil_objetivo		-	-	-	Insano	-
verduras	Mín.	2	0	1	2	0
	Máx	3	2	2	3	3
frutas	Mín.	3	0	1	3	0
	Máx	4	2	3	4	4
lacteos	Mín.	0	0	0	0	0
	Máx	2	1	1	2	2
pescado	Mín.	3	0	1	3	0
	Máx	4	2	3	4	4
carnes	Mín.	2	3	1	2	2
	Máx	3	6	4	3	6
huevos	Mín.	3	0	1	3	0
	Máx	5	4	4	5	5
legumbres	Mín.	2	0	1	2	0
	Máx	4	2	3	4	4
carnes_grasas	Mín.	0	2	0	0	0
	Máx	2	3	2	2	3
primer_nivel	Mín.	0	1	0	0	0
	Máx	1	4	2	1	4
segundo_nivel	Mín.	0	2	0	0	0
	Máx	2	5	3	2	4
sexto_nivel	Mín.	1	0	1	1	0
	Máx	1	2	1	1	2
pan		80	90	80	80	80
bebida		0	50	10	20	50
cafe_semana	Mín.	0	4	1	1	1
	Máx	0	5	5	4	3
cafe_dia	Mín.	0	1	0	1	0
	Máx	0	2	1	2	1
alcohol_semana	Mín.	0	0	0	0	0
	Máx	0	2	1	2	3
alcohol_dia	Mín.	0	0	0	0	1
	Máx	0	1	1	1	1

Parámetros Asociados al Grupo de Alimentos

Los valores de los parámetros asociados al grupo de alimentos dependen **directamente** del perfil en cuestión. Como los parámetros descritos en este subtipo se relaciona con la **frecuencia** con la que se consumen alimentos saludables (exceptuando el parámetro «carnes_grasas»), los perfiles que se asemejen a una dieta sana tendrán unos valores mínimos y máximos **mayores** que aquellos perfiles que se definan como insanos.

Parámetros Asociados al Grado de ingesta

De manera similar, los valores asociados al grado de ingesta se relacionan **directamente** con la **calidad** de la dieta. Para un perfil **sano**, los valores (tanto mínimos como máximos) de los parámetros de primer y segundo nivel serán mucho **menores** que aquellos perfiles insanos. Por otro lado, los valores para los parámetros de nivel seis serán **mayores** en perfiles más sanos.

Parámetros Asociados al Pan y Bebidas

En este último subtipo, el rango de valores depende de la **tendencia** que tiene el perfil al consumo de **pan** y de **bebidas**, así como del **café** y del **alcohol**. Por lo tanto, estos valores también dependen **directamente** del **perfil** y de la asignación que se le haya dado.

4.3. Creación de la Base de Datos Sintética

En esta sección se describe el proceso en el que se crea la **base de datos sintética a partir de los perfiles de hábitos de comportamiento alimenticio** que se han descrito anteriormente. Para cada uno de los 15 perfiles, se han generado un conjunto de **usuarios únicos** que simulan una dieta asociada a ese perfil y en el que se diferencian tanto de la región del mundo a la que pertenece cada usuario, como de los parámetros que aleatoriamente ha asignado el programa. El procedimiento utilizado para generar la dieta de cada usuario se describe a continuación:

- En primer lugar, se **obtienen** los valores de los **parámetros** según el perfil deseado (tal como se muestra en la Tabla 4.4). Además, se le **asigna** una de las **regiones** disponibles.
- Después, se **calcula** un número **aleatorio** entre estos valores numéricos, obteniendo así un número en cada parámetro que indica la **frecuencia**.
- Una vez asignados valores a los 25 parámetros, se inicia el proceso de **distribución y balanceo**: por un lado, como los valores de los parámetros indican una frecuencia de consumo de un determinado grupo alimentario o grado de ingesta, cada unidad de frecuencia se distribuye (también de manera aleatoria) entre los 7 días de la semana o entre las comidas establecidas por día (dependiendo del tipo de parámetro). Por ejemplo, si se ha asignado una frecuencia de 3 días para el consumo de pescado, esta se repartirá en 3 días de la semana (esto es, lunes, martes y domingo). Para que haya un reparto equitativo, por otro lado, se balancea de manera que todos los días y todas las comidas tengan un reparto justo. De esta manera, los diferentes grupos y productos alimentarios se encuentran repartidos entre los distintos días y comidas de la semana.
- Finalmente, para cada día y comida, se **escoge de manera aleatoria un plato** perteneciente al grupo alimentario o grado de ingesta en el que se encuentra. La única restricción es que el **plato** sea de carácter **internacional** o coincida con la **región** del usuario.

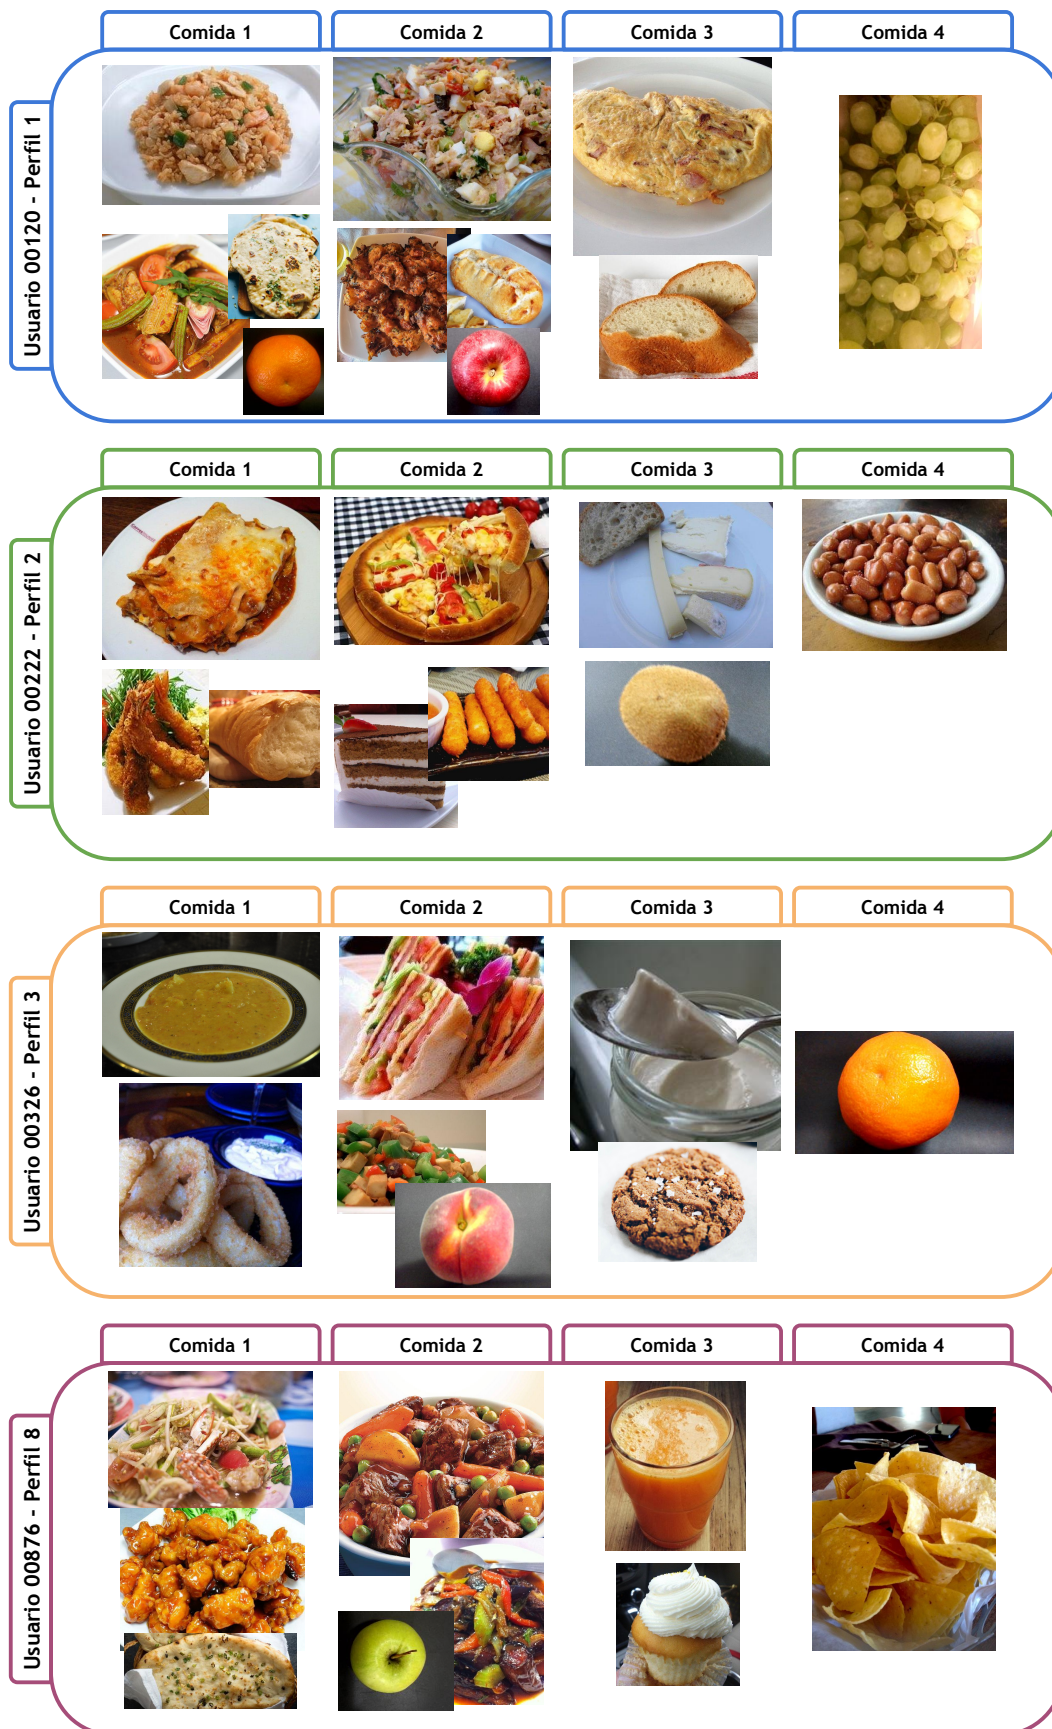


Figura 4.1: Ejemplos de dietas de un día de algunos usuarios pertenecientes a la base de datos sintética. Por perfiles, de arriba a abajo: perfil 1 (sano), perfil 2 (insano), perfil 3 (medio) y perfil 8 (consumo excesivo de carne).

En este TFM se ha creado una base de datos sintética a partir de los 15 perfiles que se han descrito previamente, generando dietas de 4 semanas (28 días). Además, se han considerado todas las regiones disponibles y se han tenido en cuenta 10 usuarios por región y perfil. Por lo tanto, al haber 8 posibles regiones y 15 perfiles, la suma total asciende a **1200 usuarios**, los cuales reflejan distintos tipos de perfiles de hábitos de comportamiento alimenticio.

En la Figura 4.1 se muestran algunos ejemplos de dietas de usuarios pertenecientes a la base de datos sintética. En ella se observan diferencias notables entre los usuarios: por ejemplo, el primer usuario (usuario 00120), que corresponde con un perfil sano, tiene una variedad de productos en los que incluye el arroz, el pescado, los vegetales y la fruta; en cambio, el segundo usuario (usuario 00222), se basa en una dieta insana, por lo que aparecen productos que se encuentran en el primer y segundo nivel como pizza, comida frita o dulces, entre otros; el usuario 00326 (tercer usuario), se ha basado en un perfil medio, por lo que incluye alimentos tanto saludables (como la sopa y los vegetales) como algunos menos sanos (comida frita o dulces); el último usuario (usuario 00876) destaca por comer mayor cantidad de carne en sus comidas, aunque también combina platos saludables con aquellos que lo son menos.

5

Experimentos: Base de Datos de Alimentos y Grupos Alimentarios

En este capítulo se describen los experimentos para la base de datos de alimentos y grupos alimentarios generada. Para ello, se ha utilizado un sistema de reconocimiento de alimentos basado en *Deep Learning* y se ha evaluado previamente con algunas bases de datos que conforman el Estado del Arte. Seguidamente, se ha evaluado este mismo sistema con la **base de datos generada** y una vez se han obtenido los rendimientos para los diferentes experimentos propuestos, se han **analizado** los resultados y extraído las **conclusiones**.

5.1. Sistema Propuesto

El sistema de reconocimiento de alimentos que se ha propuesto está basado en **CNN**, debido a los rendimientos tan **efectivos** que han tenido en previos estudios (véase Sección 2.2.2). En concreto, se ha utilizado la red neuronal *XceptionNet*, cuya arquitectura cuenta con 36 capas convolucionales repartidas en 14 módulos distintos. Esta red neuronal ha demostrado tener un **mejor rendimiento** frente a otras CNN tales como *Inception*, *VGG* o incluso *ResNet* [78].

Siguiendo un procedimiento similar al realizado en [79], en el cual se ha empleado la técnica *fine-tuning*, se han seguido los siguientes pasos para la fase de entrenamiento del modelo:

1. En primer lugar, se ha empleado un modelo pre-entrenado con la base de datos *ImageNet* [80], una técnica que se ha utilizado en numerosos estudios. De esta manera, el modelo es capaz de diferenciar más de 1.000 clases que comprenden un gran variedad de objetos y seres vivos.
2. La última capa de la arquitectura (*fully-connected layer*), la cual se encarga de clasificar las imágenes, es reemplazada por una similar con el número de clases que se requiera. Como se detalla más adelante, este número varía dependiendo del tipo de experimento que se realice.
3. A continuación, todas las capas de la CNN se congelan, a excepción de la capa *fully-connected*. Esta última capa se entrena durante 5 épocas.

Tabla 5.1: Bases de datos evaluadas que pertenecen al Estado del Arte.

Base de Datos	Imágenes / Categorías	Conjunto de Entrenamiento	Conjunto de Validación	Conjunto de Evaluación
<i>Food-11</i>	16.643 / 11	9.866 (59,28 %)	3.430 (20,61 %)	3.347 (20,11 %)
<i>VIPER-FoodNet</i>	14.991 / 82	10.463 (69,80 %)	1.562 (10,42 %)	2.966 (19,79 %)
<i>MAFood-121</i>	21.175 / 121	15.298 (72,25 %)	2700 (12,75 %)	3.177 (15 %)

4. Por último y con el objetivo de que todas las capas se adapten a la nueva base de datos, todas las capas se descongelan y se entrenan durante 10 épocas más.

Por otro lado, se han considerado las siguientes características para todos los experimentos:

- El modelo utilizado para la clasificación final corresponde con el que ha obtenido mejores rendimientos durante el entrenamiento, teniendo en cuenta el *accuracy* logrado en validación.
- La función de coste utilizada ha sido el optimizador *Adam* basada en *binary cross-entropy* y con los siguientes parámetros:
 - *Learning rate* = 0,002
 - $\beta_1 = 0,9$
 - $\beta_2 = 0,999$
- Las dimensiones de las imágenes para el *input* de las CNN ha sido de $224 \times 224 \times 3$, usando un *batch size* de 16 y utilizando la técnica *data augmentation* para una mejora del rendimiento y una reducción del posible *overfitting*.
- La tarjeta gráfica usada para los experimentos ha sido la *NVIDIA GeForce RTX 2080 Ti GPU*.

5.2. Protocolo Experimental

Antes de evaluar el sistema de reconocimiento de alimentos con la base de datos generada, se ha realizado una serie de experimentos con algunas de las bases de datos que se encuentran en el Estado del Arte. Los conjunto de datos se han seleccionado debido a las diferencias que tienen entre ellos en términos número de categorías: se trata de ***Food-11*** [30], ***VIPER-FoodNet*** [12] y ***MAFood-121*** [6], con **11**, **82** y **121** categorías, respectivamente. Además, otro factor destacable es que estos 3 conjuntos de datos **forman parte de las bases de datos escogidas para la generación de la base de datos propuesta** en este estudio. Por otro lado, los autores de estas bases de datos proponen un protocolo experimental que se ha seguido en este estudio. De este modo, los conjuntos de datos se han dividido en un conjunto de desarrollo y un conjunto de evaluación. Por su parte, el conjunto de desarrollo se divide a su vez en entrenamiento y validación, como se observa en la Tabla 5.1.

En segundo lugar, el **protocolo experimental** seguido en este TFM para la base de datos propuesta ha tenido en cuenta **3 escenarios distintos**. La diferencia de estos escenarios se debe a cómo ha sido el proceso de división del conjunto de datos: en el escenario 1 y 2 (categoría y subcategoría), la división se ha realizado a nivel de **categoría principal** y **subcategoría**, respectivamente; mientras que en el escenario 3 (producto), la partición se ha centrado en los diferentes **productos** que componen la base de datos.

Tabla 5.2: Protocolos definidos para los 5 experimentos propuestos.

Escenario	Experimento	Imágenes / Clases	Conjunto de Entrenamiento	Conjunto de Validación	Conjunto de Evaluación
1 - Categoría	Experimento 1	579.540 / 19	371.931 (64,18 %)	84.754 (14,62 %)	122.855 (21,20 %)
	Experimento 2	579.540 / 19	370.905 (64 %)	92.730 (16 %)	115.905 (20 %)
2 - Subcategoría	Experimento 3	566.667 / 58	356.715 (62,95 %)	89.545 (15,80 %)	120.407 (21,25 %)
	Experimento 4	579.540 / 72	370.905 (64 %)	92.730 (16 %)	115.905 (20 %)
3 - Producto	Experimento 5	579.540 / 912	370.924 (64 %)	92.717 (16 %)	115.899 (20 %)

Además, para los dos primeros escenarios se han considerado **dos casos** adicionales: en el primero de ellos (Experimento 1 y 3), se ha tenido en cuenta el **producto** a la hora de la partición, por lo que las imágenes de un mismo producto solo pueden encontrarse en **un solo conjunto de datos**; por otro lado, en el segundo caso (Experimento 2 y 4) esta **restricción se elimina** y las imágenes de un producto pueden aparecer en **cualquiera** de los **3 conjuntos** de datos (entrenamiento, validación o evaluación). De esta manera, se analiza la habilidad de los modelos ante **5 escenarios** de distinta complejidad.

No obstante, para todos los escenarios se ha planteado una distribución similar, donde alrededor del **80 %** de las imágenes (o en su defecto de los productos) se van a encontrar en el **conjunto de desarrollo** y el **20 %** restante, en el conjunto de **evaluación final**. A su vez, el conjunto de desarrollo se divide de la misma manera: el **80 %** (aproximadamente un 64 % del total) se ubican en el **conjunto de entrenamiento**, y el **20 %** (alrededor de un 16 % del total) en el de **validación**. En la Tabla 5.2, se muestran las distribuciones de las imágenes en los diferentes conjuntos de datos.

La diferencia en el número de imágenes en el experimento 3 respecto a los demás, se debe a que en algunas subcategorías como «Café», el número de productos es menor a 3, por lo que esta subcategoría no se puede incluir en los 3 conjuntos de datos. De este modo, el número de categorías es menor que en el experimento 4 (58 frente a 72). En el resto de casos, tanto el número de imágenes como el número de categorías, subcategorías y productos coincide con el de la base de datos generada. El número de clases en cada experimento, por tanto, corresponde también con estos valores, por lo que los experimentos desarrollados tiene en cuenta tanto las categorías generales (*coarse-grained*), como los productos únicos (*fine-grained*).

5.3. Resultados Experimentales

Tras haber descrito los protocolos experimentales, se han entrenado y evaluado los modelos con los diferentes conjuntos de datos. Los resultados que se han obtenido se encuentran en términos de **accuracy** (Acc.), que indica el porcentaje de aciertos que el sistema ha tenido frente al número total de imágenes. Además, se ha teniendo en cuenta la mejor predicción del sistema (**Top 1 acc**) y las 5 mejores primeras (**Top 5 acc**). En este último caso, se considera acierto si el modelo ha predicho la clase entre las 5 con mayor probabilidad.

5.3.1. Evaluación Frente a Bases de Datos del Estado del Arte

En primer lugar, se ha realizado una primera **evaluación** con las **3 bases de datos** que se han descrito anteriormente (*Food-11*, *VIPER-FoodNet* y *MAFood-121*) y que corresponden con algunas de las que conforman el Estado del Arte. Como se muestra en la Tabla 5.3, los rendimientos logrados en *Top 1 Acc.* son muy dispares entre las bases de datos: mientras que *Food-11*, alcanza el mejor rendimiento con un **94,08 %**, tanto *Viper-FoodNet* como *MAFood-121* bajan del 75 %, con un **64,21 %** y un **72,33 %**, respectivamente. En cambio, en términos de *Top*

Tabla 5.3: Resultados obtenidos en evaluación para las bases de datos correspondientes al Estado del Arte.

Base de Datos	Rendimientos	
	Top 1 Acc. (%)	Top 5 Acc. (%)
<i>Food-11</i>	94,08	99,46
<i>Viper-FoodNet</i>	64,21	96,32
<i>MAFood-121</i>	72,33	91,34

5 Acc., los rendimientos superan el 90 %, donde *Food-11* obtiene un **99,46 %**, *Viper-FoodNet* un **96,32 %** y *MAFood-121*, un **91,34 %**, lo que mejora drásticamente la anterior situación.

Debido a la disparidad en los resultados, se ha analizado cada una de las bases de datos. Por un lado, *Food-11* cuenta con más de **1.500 imágenes** por cada una de las **11 clases** frente a las menos de **200** que incluyen las dos bases de datos restantes. Esto supone un entrenamiento con un número de imágenes muy limitado, por lo que el modelo no va a extraer las características suficientes de cada clase, aun habiendo aplicado técnicas de *data augmentation*. Además, la base de datos *Viper-FoodNet* ofrece imágenes de sus categorías en las que muestran los productos en **múltiples formas y escenarios**, factor que justifica la disminución del rendimiento. Por otra parte, aunque las categorías de *Food-11* sean de carácter muy general, las imágenes que incluye son mucho más **similares** entre sí, lo que favorece un mayor reconocimiento. En último lugar, las 3 bases de datos están compuestas por un número de clases muy diferentes entre sí, como se ha expuesto previamente. Este hecho demuestra que hay una mayor **dificultad** a la hora de reconocer grupos de alimentos más **específicos**.

5.3.2. Evaluación Frente a la Base de Datos de Alimentos y Grupos Alimentarios Generada

En segundo lugar, se ha realizado una evaluación en profundidad en la base de datos de alimentos y grupos alimentarios generada, teniendo en cuenta los **5 experimentos** descritos anteriormente. Una vez se han obtenido los resultados, se han comparado entre los experimentos del mismo y diferente escenario. En la Tabla 5.4, se muestran todos los rendimientos para cada uno de los experimentos desarrollados, donde en **negrita** se señalan aquellos que han logrado los mejores resultados.

En el escenario 1 se ha llevado a cabo la evaluación propuesta en términos de **categorías**. Por lo tanto, las imágenes de las **19 clases** se han utilizado como conjunto de datos. En el **experimento 1** (diferentes productos se han utilizado para el entrenamiento y evaluación de los sistemas dentro de la misma categoría), se ha obtenido un **57,13 %** y un **90,43 %** en *Top 1 Acc.* y *Top 5 Acc.*, respectivamente. En cambio, el experimento 2 (mismos productos, aunque diferentes imágenes, para la fase de entrenamiento y evaluación de los sistemas), los rendimientos logrados son notablemente mejores: un **77,50 %** en *Top 1 Acc.* y un **97,92 %** en *Top 5 Acc.*, lo que mejora en más de 20 y 7 puntos frente al primer experimento, respectivamente. Como es de suponer, esta gran diferencia viene marcada por la **distinción de los productos** en cada experimento: el modelo entrenado del primer experimento **no tiene la capacidad de generalizar entre productos de una misma categoría**, mientras que el segundo modelo extrae características de las categorías de una manera más efectiva.

En el escenario 2, se observa un comportamiento similar al anterior: mientras que en el experimento 3 (que tiene en cuenta el producto), se alcanzan rendimientos muy bajos -un **43,45 %** en *Top 1 Acc.* y un **69,79 %** en *Top 5 Acc.*-, en el experimento 4, el cual no tiene en cuenta el producto, los resultados superan en casi 30 puntos en *Top 1 Acc.* (**72,01 %**) y más de 20 puntos

Tabla 5.4: Rendimientos obtenidos en evaluación para los diferentes experimentos realizados de la base de datos de alimentos y grupos alimentarios generada. En **negrita** se señalan los mejores resultados en cada escenario.

Escenario	Experimento	Rendimientos	
		Top 1 Acc. (%)	Top 5 Acc. (%)
1 - Categoría	Experimento 1	57,13	90,43
	Experimento 2	77,50	97,92
2 - Subcategoría	Experimento 3	43,45	69,75
	Experimento 4	72,01	93,23
3 - Producto	Experimento 5	52,05	79,74

en *Top 5 Acc.* (**93,23 %**). En este caso, muchas de las subcategorías que se han definido representan productos cuya apariencia es muy similar respecto de otras subcategorías (como puede ser «**Carne Roja**» y «**Carne Mixta**»), por lo que los modelos son menos capaces de clasificar de manera correcta entre las diferentes clases. Además, si los productos solo se encuentran en un conjunto de datos (como ocurre en el experimento 3), el modelo tendrá una dificultad añadida a la hora de reconocer las diferentes subcategorías y como consecuencia, los rendimientos alcanzan apenas el 40%. Por otro lado, al comparar los dos primeros escenarios con los mejores rendimientos, se observa un empeoramiento de alrededor del **5 %** en el segundo escenario, hecho que se contrasta con la dificultad que tienen los modelos para extraer características únicas de cada clase.

Por último, en el escenario 3 (Experimento 5) se han obtenido unos rendimientos bastante más bajos que en los anteriores escenarios (escogiendo solo los mejores resultados): en *Top 1 Acc.*, el rendimiento alcanzado es de **52,05 %**, mientras que en *Top 5 Acc.*, esta cifra sube hasta el **79,74 %**. De manera similar, se observa que cuanto más específico es la tarea, mayor dificultad tienen los modelos de detectar correctamente la clase. En este sentido, hay un gran porcentaje de los **912 productos** que forman este conjunto de datos que tienen una apariencia semejante entre ellos. Por ejemplo, unas patatas fritas se pueden parecer en un alto porcentaje a unas patatas fritas con queso. De esta manera, el modelo es incapaz de discernir estas diferencias y en consecuencia, se ve reflejado en los rendimientos obtenidos.

En conclusión, se ha realizado un análisis exhaustivo de los resultados que se han obtenido en las evaluaciones efectuadas. Por un lado, los rendimientos logrados en las bases de datos del Estado del Arte indican un gran acierto a la hora de reconocer grupos de alimentos más generales, superando el **90 %** para *Top 1 Acc.* y el **99 %** para *Top 5 Acc.*. De la misma manera, los resultados que se han alcanzado en la base de datos propuesta en este TFM, señalan la dificultad que tienen los modelos en reconocer grupos de alimentos más específicos, debido principalmente a la similitud que hay entre los grupos más parejos. No obstante, teniendo en cuenta el *Top 5 Acc.* se observa que los modelos se acercan a un escenario ideal, con rendimientos que superan en algunos casos el **97 %**.

6

Experimentos: Base de Datos de Hábitos de Comportamiento Alimenticio

En este capítulo se analizan los experimentos realizados en la base de datos sintética generada a partir de los **perfiles de hábitos de comportamiento alimenticio**. En primer lugar, se ha **examinado** la **dieta** de los usuarios basados en los diferentes perfiles creados y se ha efectuado el correspondiente **análisis**. En segundo lugar, se han **comparado** los usuarios entre sí a partir de **métricas multidimensionales** y se ha **analizado la calidad** de la dieta de cada usuario.

6.1. Análisis Dietético

En el Capítulo 4, se ha generado una base de datos sintética con **1.200 dietas** de usuarios que pertenecen a distintos perfiles de hábitos de comportamiento alimenticio. Estos perfiles, además, se han creado a partir de diferentes criterios establecidos, por lo que se encuentran tanto perfiles con una **alimentación sana** como **insana**. De este modo, es importante distinguir entre aquellos usuarios que se alimentan de manera apropiada frente a los que se nutren a base de comida insana. Por ello, se ha realizado un primer análisis de los usuarios que permita, de **manera visual**, detectar las **irregularidades** en su dieta. Asimismo, permite tanto localizar aquellos grupos de alimentos donde el usuario debería de tener una frecuencia de consumo mayor, como de aquellos en los que hay un exceso y por tanto, esta frecuencia de consumo se tendría que reducir.

Atendiendo a las recomendaciones que se han visto reflejadas en la Sección 2.3.1, se ha generado un análisis mediante gráficas que muestran la frecuencia de ingesta de los grupos de alimentos con mayor impacto en la salud, indicando en cada uno de ellos la franja de frecuencias recomendadas. El análisis se ha realizado por semanas, ya que se ha demostrado que es una buena forma de controlar la ingesta de los diferentes alimentos. Como se observa en la Figura 6.1, los grupos de alimentos de **frecuencia diaria** son: frutas, verduras y, arroz y pasta (este último también pertenece al grado de ingesta 6). Por otro lado, los grupos de alimentos de **frecuencia** semanal **escogidos** son: pescado, carnes, huevos, legumbres, y alimentos que se encuentran dentro del grado de ingesta 1 y 2. Por lo tanto, se ha hecho una distinción entre aquellos alimentos que deben de encontrarse de **manera abundante** (frecuencia diaria) frente aquellos con **menor regularidad** (frecuencia semanal).




Figura 6.1: Análisis de dos frecuencias de ingesta de diferentes grupos alimentarios. En la gráfica de arriba, se observa un usuario con un perfil de hábito alimentario saludable, mientras que en la gráfica de abajo, corresponde con un perfil insano. Para cada grupo de alimento, se indica en la figura los rangos óptimos (en color verde) para una dieta saludable según los organismos internacionales.

De este modo, en la parte izquierda de la gráfica se muestran los alimentos pertenecientes a la frecuencia diaria y para ello, se ha contabilizado el número de productos que se **ingieren** en toda **una semana** y que se encuentran en estos grupos. Seguidamente, se ha dividido este número entre los días de la semana (7), obteniendo así la frecuencia media diaria del usuario en una determinada semana. Por otro lado, se ha seguido un procedimiento similar para los productos del resto de grupos alimentarios (parte derecha de la gráfica), contabilizando la ingesta en los 7 días de la semana. Finalmente, la frecuencia de ingesta de los grupos alimentarios seleccionados se muestran en las gráficas, donde se observa tanto la **frecuencia de cada grupo** como los **rangos** en los que se debe encontrar el valor para que se adecue a las recomendaciones saludables.

En este sentido, se han tomado algunos ejemplos de usuarios con perfiles diferentes: en la Figura 6.1, se muestran dos tipos de perfiles distintos: en la gráfica de arriba, se muestra el **usuario 00100**, que corresponde con un perfil sano (perfil 1). Como se aprecia, la frecuencia de ingesta de todos los grupos alimentarios se encuentran **dentro de los límites establecidos**, por lo que su alimentación en esa semana se considera como **saludable**. En el otro extremo se encuentra el **usuario 00224** (gráfica de abajo), asociado con un perfil insano (perfil 2). En este caso, hay un **consumo escaso** de frutas, verduras, y arroz y pasta, entre otros. Por otro lado, se ha detectado un **consumo excesivo de carne** y alimentos procedentes de los **grados de ingesta 1 y 2**, por lo que su ingesta tendría que ser menor para seguir las directrices correctas hacia una alimentación más saludable.

6.2. Evaluación de la Base de Datos Sintética

Por otra parte, se han utilizado **métricas multidimensionales** para comparar la **calidad de la dieta** de un usuario perteneciente a la base de datos sintética. Para ello, se ha utilizado la distancia de **Mahalanobis** (MD), que calcula la **similitud** entre variables aleatorias con multidimensionalidad [81]. A diferencia de la distancia Euclídea, esta considera la **correlación** entre las variables aleatorias y su interpretación estadística viene definida como:

$$MD_i = \sqrt{(x_i - \bar{x})C_x^{-1}(x_i - \bar{x})^T} \quad (6.1)$$

En este caso, x_i corresponde con cada variable y \bar{x} es el vector de valores promedios de estas variables. Por otro lado, C_x^{-1} es la inversa de la matriz de covarianza resultante. Entre las propiedades como distancia, tiene que cumplir la semipositividad (en la que el valor tiene que ser mayor o igual que cero y en caso de variables iguales, MD debe ser 0) y la simetría (la distancia entre un punto y otro es el mismo en ambas direcciones), entre otros.

De manera análoga con la sección previa, cada uno de los grupos alimentarios y grados de ingesta con mayor impacto corresponden con una variable que se utilizará como características para calcular la distancia. Además, la **matriz de covarianza** se computa a partir de estas variables definidas: frutas, verduras, y arroz y pasta (como grupos pertenecientes a alimentos de frecuencia diaria), y pescado, carnes, huevos, legumbres y alimentos que se encuentran dentro del grado de ingesta 1 y 2 (como grupos que componen los alimentos de frecuencia semanal). Antes de calcular la distancia de **Mahalanobis** con dichas características de consumo diarias y semanales por grupo alimentario, se debe definir la matriz de covarianza a partir de estas variables y para ello, se han de asignar los valores de cada variable para poder cuantificar la calidad de la dieta.

En este sentido, se han tenido en cuenta las **frecuencias mínimas y máximas** de cada grupo alimentario siguiendo las recomendaciones de alimentación saludable. De esta manera, se ha formado el **vector de características** correspondiente con el **perfil ideal** (es decir, un

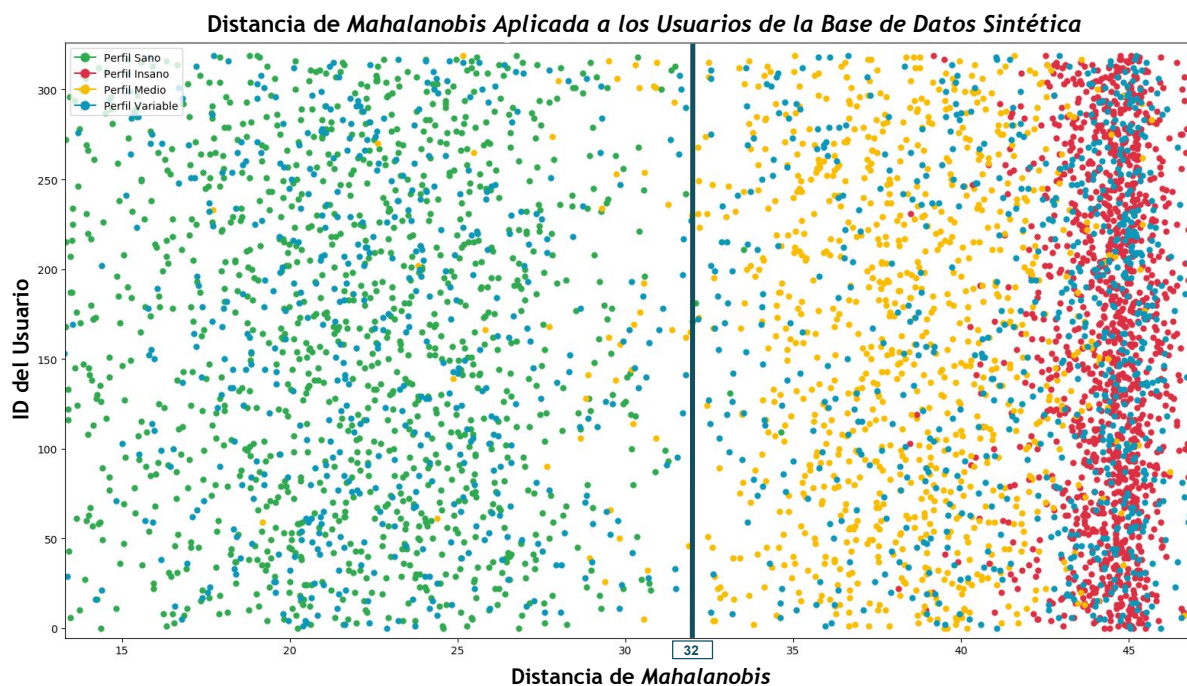


Figura 6.2: Distancia de Mahalanobis Aplicada a los Usuarios de la Base de Datos Sintética.

perfil de hábito de comportamiento alimenticio sano). A raíz de ello, se ha calculado la matriz de covarianza y se ha evaluado la distancia de *Mahalanobis* para cada una de las dietas semanales de los usuarios. Por lo tanto, cada usuario tiene 4 vectores de características asociados a cada una de las semanas que conforman su dieta, de tal manera que cada uno de las **9 variables** que componen el vector se asocian con cada una de las frecuencias de consumo correspondientes. Al calcular la distancia de *Mahalanobis* con cada uno de los vectores asociados a los usuarios, se obtiene un valor que **indica la distancia que está la dieta semanal respecto de una dieta** que sigue unas recomendaciones de **alimentación saludable**.

En la Figura 6.2, se muestran los resultados tras aplicar la **distancia de Mahalanobis** a los 1.200 usuarios durante las 4 semanas (y por lo tanto, 4.800 dietas diferentes). En ella, se han considerado **4 tipos de perfiles generales** (los cuales corresponden con los definidos en la Sección 4.2) y se han marcado con un color distinto: sano (verde), insano (rojo), medio (amarillo) y perfil variable (azul). Al analizar la gráfica, se observa cómo los usuarios con un tipo de perfil sano (verde) tienden a valores que se **acercan a 0**, mientras que los usuarios con un tipo de perfil insano (rojo), **se alejan**. Además, se observa una gran distancia entre ambos perfiles, lo que denota una clara diferenciación. Finalmente, los perfiles medios (amarillo) se localizan la mayoría **junto a los perfiles menos sanos**; mientras que los perfiles variables, se ubican todo el área que cubren tanto los perfiles sanos como los insanos. Este último caso es razonable ya que el perfil variable **alterna semanas** en los que su alimentación es más o menos sana a lo largo de ellas.

6.2.1. Clasificación Binaria Mediante Umbrales

A continuación, se ha llevado a cabo un experimento para **evaluar la calidad de una dieta** en base a la distancia de *Mahalanobis*: en este caso, se trata de una **clasificación binaria por medio de umbrales**, en el que se indica si una dieta es sana o no. Por tanto, únicamente los perfiles sanos serán tratados como tal, mientras que los perfiles insano y medio, serán tratados como insanos, mientras que el resto de perfiles variables no se han tenido en cuenta debido a sus

irregulares dietas. En resumen, 6 perfiles se definen como **no sano** frente a los 4 perfiles **sanos**. Al haber 80 usuarios por perfil y 4 semanas por usuario, el conjunto total de datos asciende a **3.200**.

A continuación, se han realizado una serie de pruebas con el fin de obtener un valor umbral que maximizara la tasa de acierto a la hora de clasificar una dieta. Tras examinar diferentes umbrales, se ha seleccionado el umbral con valor **32** (véase Figura 6.2): los resultados que se han obtenido demuestran la eficacia del valor asignado, ya que solo ha habido **5 fallos** en la clase positiva (un perfil sano se ha detectado como insano) frente a los **10 fallos** en la clase negativa (3 perfiles insanos se han detectado como sanos), clasificando un total de **3.200 dietas**. Por consiguiente, la tasa de aciertos (esto es, la suma de aciertos dividido por el número total de datos) supera el **99 %**.

En este capítulo se ha analizado la base de datos sintética de dietas de usuarios que se ha generado previamente. Para ello, se han utilizado dos tipos de análisis basados en **gráficas de frecuencias** y en la **distancia de Mahalanobis**. Ambos análisis han demostrado que a partir de lo que una persona ingiere durante una semana, se puede **indicar la calidad de una dieta** en base a si su alimentación es sana o no, debido a que se ha mostrado una clara diferencia entre los perfiles saludables y aquellos que no.

7

Conclusiones Finales y Trabajo Futuro

7.1. Conclusiones Finales

En este TFM se ha presentado el **primer entorno programable que permite generar bases de datos sintéticas que reflejan diferentes tipos de perfiles de hábitos de comportamiento alimenticio**. Para ello, se han realizado una serie de procesos previos que han dado lugar al entorno final, entre los que destacan la generación de una base de datos de alimentos y grupos alimentarios, la creación de perfiles que simulan diferentes hábitos de comportamiento alimentario y finalmente, la implementación del entorno que combina los previos procesos.

En primer lugar, se ha realizado un estudio exhaustivo sobre las bases de datos de alimentos que conforman el Estado del Arte. Tras examinar cada una de ellas, se han seleccionado **7** debido a las características únicas que aportaban. Más tarde, se han clasificado cada uno de los más de **1.100 productos** encontrados en las bases de datos y se han agrupado en **19 categorías generales** considerando los grupos alimentarios existentes. Además, en cada categoría se ha realizado una segunda clasificación teniendo en cuenta las diferencias de los productos de un mismo grupo alimentario, por lo que finalmente se han formado un total de **72 subcategorías**. Como resultado, la base de datos generada cuenta con más de **500.000 imágenes de alimentos** que comprenden casi la totalidad de los grupos alimentarios y que ofrece una gran diversidad de productos de diferentes regiones del mundo. De esta manera, la base de datos propuesta es una pieza fundamental a la hora de desarrollar el entorno programable.

En segundo lugar, se han creado un conjunto de perfiles que reproducen diferentes hábitos de comportamiento alimentario en la vida real. Para ello, se ha tenido en cuenta las diferentes **recomendaciones de alimentación saludable** que proponen algunas organizaciones tanto a nivel nacional como internacional. De este modo, se ha establecido un perfil con un hábito de comportamiento saludable basado en estas recomendaciones. A partir de este punto, se han generado un total de **15 perfiles** con diferentes grados en la calidad de sus dietas alimentarias, por lo que se encuentran tanto perfiles asociados a una alimentación saludable, como otros que simulan una alimentación insana.

En consecuencia, se ha desarrollado un entorno programable que permite generar bases de datos sintéticas a partir de los perfiles generados previamente. Por ello, la base de datos de alimentos y grupos alimentarios aporta las diferentes imágenes de los productos que se encontrarán

en cada una de las dietas marcadas por cada perfil definido. En este TFM se ha propuesto un total de **80 usuarios** por cada perfil, lo que ha generado una base de datos sintética de **1.200 usuarios**. Además, cada una de las dietas tiene una duración de 4 semanas.

Por otra parte, se han analizado ambas bases de datos con el objetivo de evaluar su calidad. La base de datos de alimentos y grupos alimentarios, por un lado, presenta un gran desafío ante los modelos basados en CNN, los cuales apenas alcanzan el 80 % en *Top 1 Acc*. La gran diversidad que presentan los diferentes productos de una misma categoría imposibilitan la labor de detección por parte de las CNN, las cuales mejoran su rendimiento notablemente en *Top 5 Acc*. Por otro lado, la base de datos sintética que se ha generado ha permitido analizar el comportamiento alimenticio de cada usuario, donde posteriormente se ha podido evaluar la calidad de su dieta a partir de análisis gráficos y de la distancia de *Mahalanobis*.

7.2. Limitaciones y Trabajo Futuro

Algunos aspectos desarrollados en este TFM son mejorables: la base de datos de alimentos y grupos alimentarios se ha generado a partir de unos criterios basados en recomendaciones generales por parte de organizaciones, por lo que se han encontrado limitaciones a la hora de llevar a cabo algunos procesos dentro de este marco. Del mismo modo, los perfiles de hábitos de comportamiento alimenticio se han creado a partir de los mismos criterios utilizados anteriormente, lo que conlleva a una imparcialidad a la hora de definir cada uno de estos perfiles. Entre las líneas de investigación que pueden dar lugar a trabajos futuros, se encuentra:

- Este TFM se encuentra dentro del proyecto AI4FOOD, el cual propone usar los últimos avances en Inteligencia Artificial para revolucionar la nutrición personalizada. Por estos motivos:
 - la nueva versión de la base de datos de alimentos y grupos alimentarios será perfilada con expertos en nutrición que valoren de una forma más competente las características de los productos, así como de las bases de datos.
 - los diferentes perfiles de hábitos de comportamiento alimenticio se crearán en base a los criterios de los profesionales en nutrición, por lo que simularán las dietas de los usuarios de una forma más real.
- Añadir mayor variedad de bases de datos de alimentos que incluyan productos que no se han contemplado en este TFM, otorgando una mayor realidad.
- Implementar arquitecturas de clasificación de alimentos más complejas que se adapten a las características de las imágenes de los productos.
- Generar perfiles en base a su posición geográfica y por tanto, que reflejen el grupo de alimentos que se consuma en determinadas regiones del planeta.

Glosario de Acrónimos

- **ANN:** *Artificial Neural Network* o red neuronal artificial.
- **CNN:** *Convolutional Neural Network* o red neuronal convolucional.
- **ENT:** Enfermedad No Transmisibile.
- **MD:** *Mahalanobis Distance* o distancia de mahalanobis.
- **OMS:** Organización Mundial de la Salud.
- **SENC:** Sociedad Española de Nutrición Comunitaria

Bibliografía

- [1] Narkpravit Chusak. An eLearning Model in Prevention of Nutrition-Related Diseases for Senior Working Adults. In *Proc. 4th International Conference on Distance Learning and Education*, pages 42–45. IEEE, 2010.
- [2] Marios M Anthimopoulos, Lauro Gianola, Luca Scarnato, Peter Diem, and Stavroula G Mougiakakou. A Food Recognition System for Diabetic Patients Based on an Optimized Bag-of-Features Model. *IEEE journal of biomedical and health informatics*, 18(4):1261–1271, 2014.
- [3] Megha Chopra and Archana Purwar. Recent Studies on Segmentation Techniques for Food Recognition: A Survey. *Archives of Computational Methods in Engineering*, pages 1–14, 2021.
- [4] Asmabee Khan, Sachin Deshpande, and Amiya K Tripathy. Optimizing Nutrition using Machine Learning Algorithms - a Comparative Analysis. In *Proc. International Conference on Nascent Technologies in Engineering (ICNTE)*, pages 1–4. IEEE, 2019.
- [5] Weiqing Min, Shuqiang Jiang, Linhu Liu, Yong Rui, and Ramesh Jain. A Survey on Food Computing. *ACM Computing Surveys (CSUR)*, 52(5):1–36, 2019.
- [6] Eduardo Aguilar, Marc Bolaños, and Petia Radeva. Food Recognition using Fusion of Classifiers Based on CNNs. In *Proc. International Conference on Image Analysis and Processing*, pages 213–224. Springer, 2017.
- [7] Zhengeng Yang, Hongshan Yu, Shunxin Cao, Qi Xu, Ding Yuan, Hong Zhang, Wenyan Jia, Zhi-Hong Mao, and Mingui Sun. Human-Mimetic Estimation of Food Volume from a Single-View RGB Image Using an AI System. *Electronics*, 10(13):1556, 2021.
- [8] Wesley Tay, Bhupinder Kaur, Rina Quek, Joseph Lim, and Christiani Jeyakumar Henry. Current Developments in Digital Quantitative Volume Estimation for the Optimisation of Dietary Assessment. *Nutrients*, 12(4):1167, 2020.
- [9] Weiqing Min, Shuqiang Jiang, Linhu Liu, Yong Rui, and Ramesh Jain. A Survey on Food Computing. *ACM Computing Surveys (CSUR)*, 52(5):1–36, 2019.
- [10] Mohammed Ahmed Subhi, Sawal Hamid Ali, and Mohammed Abulameer Mohammed. Vision-Based Approaches for Automatic Food Recognition and Dietary Assessment: A Survey. *IEEE Access*, 7:35370–35381, 2019.
- [11] Frances E Thompson and Amy F Subar. Dietary Assessment Methodology. *Nutrition in the Prevention and Treatment of Disease*, pages 5–48, 2017.
- [12] Runyu Mao, Jiangpeng He, Zeman Shao, Sri Kalyan Yarlagadda, and Fengqing Zhu. Visual Aware Hierarchy Based Food Recognition. In *Proc. International Conference on Pattern Recognition*, pages 571–598. Springer, 2021.

- [13] Luke Gemming, Jennifer Utter, and Cliona Ni Mhurchu. Image-assisted Dietary Assessment: a Systematic Review of the Evidence. *Journal of the Academy of Nutrition and Dietetics*, 115(1):64–77, 2015.
- [14] Mei Chen, Kapil Dhingra, Wen Wu, Lei Yang, Rahul Sukthankar, and Jie Yang. PFID: Pittsburgh Fast-Food Image Dataset. In *Proc. IEEE International Conference on Image Processing*, pages 289–292, 2009.
- [15] Taichi Joutou and Keiji Yanai. A Food Image Recognition System with Multiple Kernel Learning. In *Proc. 16th IEEE International Conference on Image Processing (ICIP)*, pages 285–288. IEEE, 2009.
- [16] Hajime Hoashi, Taichi Joutou, and Keiji Yanai. Image Recognition of 85 Food Categories by Feature Fusion. In *Proc. IEEE International Symposium on Multimedia*, pages 296–301. IEEE, 2010.
- [17] Y. Matsuda, H. Hoashi, and K. Yanai. Recognition of multiple-food images by detecting candidate regions. In *Proc. of IEEE International Conference on Multimedia and Expo (ICME)*, 2012.
- [18] Y. Kawano and K. Yanai. Automatic Expansion of a Food Image Dataset Leveraging Existing Categories with Domain Adaptation. In *Proc. of ECCV Workshop on Transferring and Adapting Source Knowledge in Computer Vision*, 2014.
- [19] Lukas Bossard, Matthieu Guillaumin, and Luc Van Gool. Food-101 – Mining Discriminative Components with Random Forests. In David Fleet, Tomas Pajdla, Bernt Schiele, and Tinne Tuytelaars, editors, *Proc. Computer Vision – ECCV*, pages 446–461. Springer International Publishing, 2014.
- [20] Xin Wang, Devinder Kumar, Nicolas Thome, Matthieu Cord, and Frederic Precioso. Recipe Recognition with Large Multimodal Food Dataset. In *Proc. IEEE International Conference on Multimedia & Expo Workshops (ICMEW)*, pages 1–6. IEEE, 2015.
- [21] Ruihan Xu, Luis Herranz, Shuqiang Jiang, Shuang Wang, Xinhang Song, and Ramesh Jain. Geolocalized Modeling for Dish Recognition. *IEEE transactions on multimedia*, 17(8):1187–1199, 2015.
- [22] Austin Myers, Nick Johnston, Vivek Rathod, Anoop Korattikara, Alex Gorban, Nathan Silberman, Sergio Guadarrama, George Papandreou, Jonathan Huang, and Kevin Murphy. Im2Calories: Towards an Automated Mobile Vision Food Diary. In *Proc. IEEE International Conference on Computer Vision*, pages 1233–1241, 2015.
- [23] Gianluigi Ciocca, Paolo Napoletano, and Raimondo Schettini. Food Recognition and Leftover Estimation for Daily Diet Monitoring. In *Proc. International Conference on Image Analysis and Processing*, pages 334–341. Springer, 2015.
- [24] Gianluigi Ciocca, Paolo Napoletano, and Raimondo Schettini. Food Recognition: a New Dataset, Experiments, and Results. *IEEE journal of biomedical and health informatics*, 21(3):588–598, 2016.
- [25] Giovanni Maria Farinella, Dario Allegra, and Filippo Stanco. A Benchmark Dataset to Study the Representation of Food Images. In *Proc. European Conference on Computer Vision*, pages 584–599. Springer, 2014.
- [26] Jaclyn Rich, Hamed Haddadi, and Timothy M Hospedales. Towards Bottom-up Analysis of Social Food. In *Proc. of the 6th International Conference on Digital Health Conference*, pages 111–120, 2016.

- [27] Chong-wah NGO Jing-jing Chen. Deep-based Ingredient Recognition for Cooking Recipe Retrieval. *ACM Multimedia*, 2016.
- [28] Michele Merler, Hui Wu, Rosario Uceda-Sosa, Quoc-Bao Nguyen, and John R Smith. Snap, Eat, RepEat: a Food Recognition Engine for Dietary Logging. In *Proc. of the 2nd international workshop on multimedia assisted dietary management*, pages 31–40, 2016.
- [29] Giovanni Maria Farinella, Dario Allegra, Marco Moltisanti, Filippo Stanco, and Sebastiano Battiato. Retrieval and Classification of Food Images. *Computers in Biology and Medicine*, 77:23–39, 2016.
- [30] Ashutosh Singla, Lin Yuan, and Touradj Ebrahimi. Food/Non-Food Image Classification and Food Categorization Using Pre-Trained GoogLeNet Model. In *Proc. of the 2nd International Workshop on Multimedia Assisted Dietary Management*, page 3–11. Association for Computing Machinery, 2016.
- [31] Lisette Charbonnier, Floor van Meer, Laura N. van der Laan, Max A. Viergever, and Paul A.M. Smeets. Standardized Food Images: A Photographing Protocol and Image Database. *Appetite*, 96:166–173, 2016.
- [32] Georg Waltner, Michael Schwarz, Stefan Ladstätter, Anna Weber, Patrick Luley, Meinrad Lindschinger, Irene Schmid, Walter Scheitz, Horst Bischof, and Lucas Paletta. Personalized Dietary Self-Management using Mobile Vision-based Assistance. In *Proc. of ICIAP Workshop on Multimedia Assisted Dietary Management*, 2017.
- [33] Gianluigi Ciocca, Paolo Napoletano, and Raimondo Schettini. Learning CNN-based Features for Retrieval of Food Images. In Sebastiano Battiato, Giovanni Maria Farinella, Marco Leo, and Giovanni Gallo, editors, *Proc. New Trends in Image Analysis and Processing*, pages 426–434. Springer International Publishing, 2017.
- [34] Xin Chen, Hua Zhou, Yu Zhu, and Liang Diao. ChineseFoodNet: A Large-Scale Image Dataset for Chinese Food Recognition. *arXiv preprint arXiv:1705.02743*, 2017.
- [35] Cem Güngör, Fatih Baltacı, Aykut Erdem, and Erkut Erdem. Turkish Cuisine: A Benchmark Dataset with Turkish Meals for Food Recognition. In *Proc. 25th Signal Processing and Communications Applications Conference (SIU)*, pages 1–4. IEEE, 2017.
- [36] Paritosh Pandey, Akella Deepthi, Bappaditya Mandal, and Niladri B Puhan. FoodNet: Recognizing Foods Using Ensemble of Deep Networks. *IEEE Signal Processing Letters*, 24(12):1758–1762, 2017.
- [37] Chakkrit Termritthikun, Paisarn Muneesawang, and Surachet Kanprachar. NU-InNet: Thai Food Image Recognition Using Convolutional Neural Networks on Smartphone. *Journal of Telecommunication, Electronic and Computer Engineering (JTEC)*, 9(2-6):63–67, 2017.
- [38] Saihui Hou, Yushan Feng, and Zilei Wang. VegFru: A Domain-Specific Dataset for Fine-Grained Visual Categorization. In *Proc. IEEE International Conference on Computer Vision*, pages 541–549, 2017.
- [39] Weiqing Min, Linhu Liu, Zhengdong Luo, and Shuqiang Jiang. Ingredient-Guided Cascaded Multi-Attention Network for Food Recognition. In *Proc. of the 27th ACM International Conference on Multimedia*, pages 1331–1339, 2019.
- [40] Parneet Kaur, Karan Sikka, Weijun Wang, Serge Belongie, and Ajay Divakaran. Foodx-251: A Dataset for Fine-Grained Food Classification. *arXiv preprint arXiv:1907.06167*, 2019.

- [41] Mona Jalal, Kaihong Wang, Sankara Jefferson, Yi Zheng, Elaine O Nsoesie, and Margrit Betke. Scraping Social Media Photos Posted in Kenya and Elsewhere to Detect and Analyze Food Types. In *Proc. of the 5th International Workshop on Multimedia Assisted Dietary Management*, pages 50–59, 2019.
- [42] Jianing Qiu, Frank Po Wen Lo, Yingnan Sun, Siyao Wang, and Benny Lo. Mining discriminative food regions for accurate food recognition. In *Proc. 30th British Machine Vision Conference 2019, BMVC 2019, Cardiff, UK, September 9-12, 2019*, page 158. BMVA Press, 2019.
- [43] Jens Blechert, Anja Lender, Sarah Polk, Niko A. Busch, and Kathrin Ohla. Food-Pics_Extended—An Image Database for Experimental Research on Eating and Appetite: Additional Images, Normative Ratings and an Updated Review. *Frontiers in Psychology*, 10:307, 2019.
- [44] Doyen Sahoo, Wang Hao, Shu Ke, Wu Xiongwei, Hung Le, Palakorn Achananuparp, Ee-Peng Lim, and Steven CH Hoi. FoodAI: Food Image Recognition Via Deep Learning for Smart Food Logging. In *Proc. of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pages 2260–2268, 2019.
- [45] Lixi Deng, Jingjing Chen, Qianru Sun, Xiangnan He, Sheng Tang, Zhaoyan Ming, Yongdong Zhang, and Tat Seng Chua. Mixed-Dish Recognition with Contextual Relation Networks. In *Proc. of the 27th ACM International Conference on Multimedia*, pages 112–120, 2019.
- [46] Jingjing Chen, Bin Zhu, Chong-Wah Ngo, Tat-Seng Chua, and Yu-Gang Jiang. A Study of Multi-Task and Region-Wise Deep Learning for Food Ingredient Recognition. *Proc. IEEE Transactions on Image Processing*, 30:1514–1526, 2021.
- [47] Ghalib Ahmed Tahir and Chu Kiong Loo. An Open-Ended Continual Learning for Food Recognition Using Class Incremental Extreme Learning Machines. *IEEE Access*, 8:82328–82346, 2020.
- [48] Weiqing Min, Linhu Liu, Zhiling Wang, Zhengdong Luo, Xiaoming Wei, Xiaolin Wei, and Shuqiang Jiang. ISIA Food-500: A Dataset for Large-Scale Food Recognition via Stacked Global-Local Attention Network. In *Proc. of the 28th ACM International Conference on Multimedia*, 2020.
- [49] Weiqing Min, Zhiling Wang, Yuxin Liu, Mengjiang Luo, Liping Kang, Xiaoming Wei, Xiaolin Wei, and Shuqiang Jiang. Large Scale Visual Food Recognition. *arXiv preprint arXiv:2103.16107*, 2021.
- [50] Jens Blechert, Adrian Meule, Niko A Busch, and Kathrin Ohla. Food-Pics: an Image Database for Experimental Research on Eating and Appetite. *Frontiers in psychology*, 5:617, 2014.
- [51] Feng Zhou and Yuanqing Lin. Fine-Grained Image Classification by Exploring Bipartite-Graph Labels. In *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 1124–1133, 2016.
- [52] Natta Tammachat and Natapon Pantuwong. Calories Analysis of Food Intake Using Image Recognition. In *Proc. 6th International Conference on Information Technology and Electrical Engineering (ICITEE)*, pages 1–4. IEEE, 2014.
- [53] Stergios Christodoulidis, Marios Anthimopoulos, and Stavroula Mougiakakou. Food Recognition for Dietary Assessment Using Deep Convolutional Neural Networks. In *Proc. International Conference on Image Analysis and Processing*, pages 458–465. Springer, 2015.

- [54] Keiji Yanai and Yoshiyuki Kawano. Food Image Recognition Using Deep Convolutional Network with Pre-Training and Fine-Tuning. In *Proc. IEEE International Conference on Multimedia & Expo Workshops (ICMEW)*, pages 1–6. IEEE, 2015.
- [55] Giovanni Maria Farinella, Dario Allegra, Marco Moltisanti, Filippo Stanco, and Sebastiano Battiato. Retrieval and Classification of Food Images. *Computers in biology and medicine*, 77:23–39, 2016.
- [56] Parisa Pouladzadeh, Shervin Shirmohammadi, and Abdulsalam Yassine. Using Graph Cut Segmentation for Food Calorie Measurement. In *Proc. IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, pages 1–6. IEEE, 2014.
- [57] Shulin Yang, Mei Chen, Dean Pomerleau, and Rahul Sukthankar. Food Recognition Using Statistics of Pairwise Local Features. In *Proc. IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 2249–2256. IEEE, 2010.
- [58] Parisa Pouladzadeh, Shervin Shirmohammadi, Aslan Bakirov, Ahmet Bulut, and Abdulsalam Yassine. Cloud-Based SVM for Food Categorization. *Multimedia Tools and Applications*, 74(14):5243–5260, 2015.
- [59] Mingxing Tan and Quoc Le. Efficientnet: Rethinking Model Scaling for Convolutional Neural Networks. In *Proc. International conference on machine learning*, pages 6105–6114. PMLR, 2019.
- [60] Jie Hu, Li Shen, and Gang Sun. Squeeze-and-Excitation Networks. In *Proc. of the Conference on Computer Vision and Pattern Recognition*, pages 7132–7141, 2018.
- [61] Ghalib Ahmed Tahir and Chu Kiong Loo. An Open-Ended Continual Learning for Food Recognition Using Class Incremental Extreme Learning Machines. *IEEE Access*, 8:82328–82346, 2020.
- [62] Eduardo Aguilar, Marc Bolaños, and Petia Radeva. Regularized Uncertainty-Based Multi-Task Learning Model for Food Analysis. *Journal of Visual Communication and Image Representation*, 60:360–370, 2019.
- [63] Patrick McAllister, Huiru Zheng, Raymond Bond, and Anne Moorhead. Combining Deep Residual Neural Network Features with Supervised Machine Learning Algorithms to Classify Diverse Food Image Datasets. *Computers in biology and medicine*, 95:217–233, 2018.
- [64] Niki Martinel, Gian Luca Foresti, and Christian Micheloni. Wide-Slice Residual Networks for Food Recognition. In *Proc. IEEE Winter Conference on applications of computer vision (WACV)*, pages 567–576. IEEE, 2018.
- [65] Heng Zhao, Kim-Hui Yap, Alex Chichung Kot, and Lingyu Duan. Jdnet: A Joint-Learning Distilled Network for Mobile Visual Food Recognition. *IEEE Journal of Selected Topics in Signal Processing*, 14(4):665–675, 2020.
- [66] Eduardo Aguilar, Beatriz Remeseiro, Marc Bolaños, and Petia Radeva. Grab, Pay, and Eat: Semantic Food Detection for Smart Restaurants. *IEEE Transactions on Multimedia*, 20(12):3266–3275, 2018.
- [67] US Department of Health, Human Services, et al. US Department of Agriculture. 2015–2020 dietary guidelines for Americans. December 2015, 2019.
- [68] Corinne L Bush, Jeffrey B Blumberg, Ahmed El-Sohemy, Deanna M Minich, José M Ordovás, Dana G Reed, and Victoria A Yunez Behm. Toward the Definition of Personalized Nutrition: a Proposal by the American Nutrition Association. *Journal of the American College of Nutrition*, 39(1):5–15, 2020.

- [69] Thomas Theodoridis, Vassilios Solachidis, Kosmas Dimitropoulos, Lazaros Gymnopoulos, and Petros Daras. A Survey on AI Nutrition Recommender Systems. In *Proc. of the 12th ACM International Conference on Pervasive Technologies Related to Assistive Environments*, pages 540–546, 2019.
- [70] NA Bruevich, Yu A Ivashkin, and MA Nikitina. Information Technology in the Mobile Application of Analysis and Correction of the Diet of Individual Healthy Nutrition. In *Proc. Systems of Signals Generating and Processing in the Field of on Board Communications*, pages 1–5. IEEE, 2019.
- [71] Nadia Tabassum, Abdul Rehman, Muhammad Hamid, Muhammad Saleem, Saadia Malik, and Tahir Alyas. Intelligent Nutrition Diet Recommender System for Diabetic’s Patients. *Intelligent Automation and Soft Computing*, 30(1):319–335, 2021.
- [72] Farman Ali, S.M. Riazul Islam, Daehan Kwak, Pervez Khan, Niamat Ullah, Sang jo Yoo, and K.S. Kwak. Type-2 Fuzzy Ontology–Aided Recommendation Systems for IoT–Based Healthcare. *Computer Communications*, 119:138–155, 2018.
- [73] Maryam Hazman and Amira M Idrees. A Healthy Nutrition Expert System for Children. In *Proc. E-Health and Bioengineering Conference (EHB)*, pages 1–4. IEEE, 2015.
- [74] David Ribeiro, João Machado, Jorge Ribeiro, Maria João M Vasconcelos, Elsa F Vieira, and Ana Correia de Barros. SousChef: Mobile Meal Recommender System for Older Adults. In *Proc. ICT4AgeingWell*, pages 36–45, 2017.
- [75] Vanesa Espín, María V Hurtado, and Manuel Noguera. Nutrition for Elder Care: a Nutritional Semantic Recommender System for the Elderly. *Expert Systems*, 33(2):201–210, 2016.
- [76] Piyaporn Tummark, Filipe Almeida da Conceição, João Paulo Vilas-Boas, Leandro Oliveira, Paulo Cardoso, Jorge Cabral, and Nonchai Santibutr. Ontology-based Personalized Dietary Recommendation for Weightlifting. 2013.
- [77] Damion M Dooley, Emma J Griffiths, Gurinder S Gosal, Pier L Buttigieg, Robert Hoehndorf, Matthew C Lange, Lynn M Schriml, Fiona SL Brinkman, and William WL Hsiao. FoodOn: a Harmonized Food Ontology to Increase Global Food Traceability, Quality Control and Data Integration. *npj Science of Food*, 2(1):1–10, 2018.
- [78] François Chollet. Xception: Deep Learning with Depthwise Separable Convolutions. In *Proc. of the IEEE conference on computer vision and pattern recognition*, pages 1251–1258, 2017.
- [79] Ruben Tolosana, Sergio Romero-Tapiador, Ruben Vera-Rodriguez, Ester Gonzalez-Sosa, and Julian Fierrez. DeepFakes Detection Across Generations: Analysis of Facial Regions, Fusion, and Performance Evaluation. *Engineering Applications of Artificial Intelligence*, 110:104673, 2022.
- [80] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet Classification with Deep Convolutional Neural Networks. *Advances in neural information processing systems*, 25, 2012.
- [81] Roy De Maesschalck, Delphine Jouan-Rimbaud, and Désiré L Massart. The Mahalanobis Distance. *Chemometrics and intelligent laboratory systems*, 50(1):1–18, 2000.