

ESCUELA POLITÉCNICA NACIONAL

FACULTAD DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA

ARQUITECTURA PARA SISTEMAS IOT

**ESTUDIO DE LAS ALTERNATIVAS QUE PERMITAN MEJORAR EL
RENDIMIENTO ACADÉMICO DE ESTUDIANTES
UNIVERSITARIOS, A TRAVÉS DEL MONITOREO DE SUS
HÁBITOS ALIMENTICIOS, UTILIZANDO APLICACIONES IOT**

**TRABAJO DE INTEGRACIÓN CURRICULAR PRESENTADO COMO
REQUISITO PARA LA OBTENCIÓN DEL TÍTULO DE INGENIERA EN
TECNOLOGÍAS DE LA INFORMACIÓN**

ESTEFANÍA LORENA QUIMBIULCO OÑA

estefania.quimbiulco@epn.edu.ec

DIRECTOR: SORAYA LUCÍA SINCHE MAITA, PHD

soraya.sinche@epn.edu.ec

DMQ, abril 2023

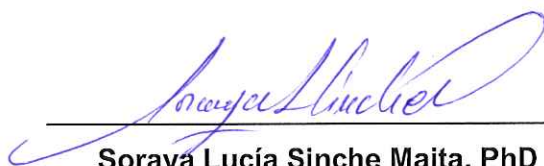
CERTIFICACIONES

Yo, ESTEFANÍA LORENA QUIMBIULCO OÑA declaro que el trabajo de integración curricular aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.



Estefanía Lorena Quimbiulco Oña

Certifico que el presente trabajo de integración curricular fue desarrollado por ESTEFANÍA LORENA QUIMBIULCO OÑA, bajo mi supervisión.



Soraya Lucía Sinche Maita, PhD

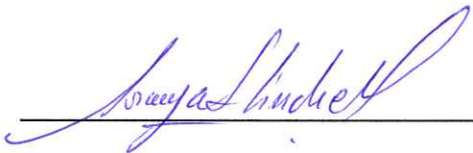
DIRECTOR

DECLARACIÓN DE AUTORÍA

A través de la presente declaración, afirmamos que el trabajo de integración curricular aquí descrito, así como el (los) producto(s) resultante(s) del mismo, son públicos y estarán a disposición de la comunidad a través del repositorio institucional de la Escuela Politécnica Nacional; sin embargo, la titularidad de los derechos patrimoniales nos corresponde a los autores que hemos contribuido en el desarrollo del presente trabajo; observando para el efecto las disposiciones establecidas por el órgano competente en propiedad intelectual, la normativa interna y demás normas.



ESTEFANÍA LORENA QUIMBIULCO OÑA



SORAYA LUCÍA SINCHE MAITA, PHD

DEDICATORIA

A mis padres, Mónica y Medardo

Por el apoyo incondicional que me supieron
brindar en mis mejores y peores momentos.

A mi hermano, Fernando

Porque fuiste y serás siempre la fuente que
me motiva alcanzar mis sueños.

A mis angelitos, Luis Emilio y Hortencia

Quienes en vida crearon recuerdos inolvidables.

A mis pequeños Adrián, Valentina y Amelia

Por ese amor tan puro e inocente.

A mis mascotas Sam, Pancha y Mateo

Por su fidelidad.

¡Los amo!

AGRADECIMIENTO

A Dios, porque escuchaste cada una de mis oraciones.

A mis padres, porque esto es fruto de su ardo trabajo.

A mi hermano, por los consejos de vida que me supiste compartir.

A mi abuelita Clemencia, por consentirme y estar pendiente de mí.

A mis amigos Karito, Josselyn, Andreita y José, por el apoyo, los consejos y salidas que compartimos.

A mi tutora la ing. Soraya Lucía Sinche Maita, por permitirme ser parte de su grupo de tesis y por los consejos académicos que me brindo a lo largo de la carrera.

A la EPN, por abrirme sus puertas del conocimiento.

Y a todas esas personas que creyeron en mí. ¡Lo logré!

ÍNDICE DE CONTENIDO

CERTIFICACIONES	i
DECLARACIÓN DE AUTORÍA	ii
DEDICATORIA	iii
AGRADECIMIENTO	iv
ÍNDICE DE CONTENIDO	v
ÍNDICE DE TABLAS	vi
ÍNDICE DE FIGURAS.....	vi
ÍNDICE DE ECUACIONES	vii
RESUMEN.....	viii
ABSTRACT	ix
1. DESCRIPCIÓN DEL COMPONENTE DESARROLLADO.....	1
1.1 Objetivo General.....	2
1.2 Objetivos Específicos	2
1.3 Alcance.....	2
1.4 Marco Teórico.....	3
1.4.1 Internet de las Cosas (IoT).....	3
1.4.2 Factores que inciden en el rendimiento académico de los estudiantes universitarios	3
1.4.3 El impacto del Internet de la Cosas en el sistema alimentario	4
1.4.4 Aplicaciones IoT en el consumo de alimentos	5
1.4.5 Sensores disponibles en dispositivos móviles.....	6
1.4.6 Conceptos básicos de Aprendizaje Automático	7
1.4.7 Indicadores de Rendimiento Académico.....	10
2. METODOLOGÍA	12
2.1 Casos de Estudio	13
2.1.1 Enfoques basados en sensores IMU	13
2.1.2 Enfoques basados en sensor micrófono	21
2.1.3 Enfoques basados en sensores piezoeléctricos	24
2.2 Sistema automático para monitoreo de hábitos alimenticios.....	29
2.3 Esquema para monitorear hábitos alimenticios utilizando un teléfono móvil	33
3. RESULTADOS, CONCLUSIONES Y RECOMENDACIONES	38
3.1 Resultados	38
3.1.1 Comparación de los casos de estudio	38
3.1.2 Porcentajes de utilización de Sensores, Ubicación del Sensor y el Algoritmo de Aprendizaje.....	40

3.1.3	Parámetros para la implementación de un futuro modelo	42
3.2	Conclusiones	44
3.3	Recomendaciones	45
4.	REFERENCIAS BIBLIOGRÁFICAS	46
5.	ANEXOS.....	I-1

ÍNDICE DE TABLAS

Tabla 1. 1	Factores que influyen en la alimentación [8][9].	4
Tabla 1. 2	Tecnología IoT implementada en cada área del sistema alimentario [12][13]. .	5
Tabla 1. 3	Principales Sensores usados para el monitoreo de hábitos alimenticios [23]. .	7
Tabla 2. 1	Enfoques basados en sensores IMU	27
Tabla 2. 2	Enfoques basados en sensores de micrófono	28
Tabla 2. 3	Enfoques basados en sensores piezoeléctricos.....	28
Tabla 3. 1	Agrupación de los parámetros más relevantes de los enfoques basados en sensores IMU.....	38
Tabla 3. 2	Agrupación de los parámetros más relevantes de los enfoques basados en sensores de micrófono.....	39
Tabla 3. 3	Agrupación de los parámetros más relevantes de los enfoques basados en sensores piezoeléctricos.....	40

ÍNDICE DE FIGURAS

Figura 1. 1	Tipos de Aprendizaje Automático basado en [21].....	9
Figura 2. 1	Metodología Kanban	12
Figura 2. 2	Prototipo del caso de estudio 1 [25]	13
Figura 2. 3	Prototipo del caso de estudio 3 [26]	14
Figura 2. 4	Prototipo del caso de estudio 6 [30]	17
Figura 2. 5	Recolección de datos del caso de estudio 8 [32].....	18
Figura 2. 6	Representación de reconocimiento de actividad [33]	19
Figura 2. 7	Prototipo del caso de estudio 10 [34]	20
Figura 2. 8	Prototipo del caso de estudio 11 [35]	20
Figura 2. 9	Prototipo del caso de estudio 12 [36]	21
Figura 2. 10	Prototipo del caso de estudio 13 [37]	22
Figura 2. 11	Prototipo del caso de estudio 15 [39]	23
Figura 2. 12	Prototipo del caso de estudio 17 [41]	24
Figura 2. 13	Prototipo del caso de estudio 18 [42]	25
Figura 2. 14	Prototipo del caso de estudio 19 [43]	25
Figura 2. 15	Sistema automático de monitoreo de hábitos alimenticios.....	29
Figura 2. 16	Fase 1: Recolección de Datos.....	30
Figura 2. 17	Fase 2: Procesamiento de Datos	31
Figura 2. 18	Fase 3: Análisis de Datos.....	32
Figura 2. 19	Fase 4: Validación de Datos.....	32
Figura 2. 20	Diseño de una aplicación móvil que permite el monitoreo de hábitos alimenticios.....	33
Figura 2. 21	Pantalla de Inicio.....	34

Figura 2. 22 Creación de Formularios	35
Figura 2. 23 Visualización de reportes	36
Figura 2. 24 Agregación de recordatorio	37
Figura 3. 1 Porcentajes de utilización de los sensores	41
Figura 3. 2 Porcentajes de ubicación de los sensores.....	42
Figura 3. 3 Porcentaje de utilización del algoritmo de aprendizaje	42

ÍNDICE DE ECUACIONES

Ecuación 1. 1 Índice de reprobación de materias	10
Ecuación 1. 2 Índice de aprobación de materias.....	10
Ecuación 1. 3 Índice de reprobación de créditos.....	10
Ecuación 1. 4 Índice de aprobación de créditos.....	10
Ecuación 1. 5 Índice de rendimiento académico	11
Ecuación 1. 6 Promedio ponderado de calificaciones	11
Ecuación 1. 7 Coeficiente de aprobación.....	11

RESUMEN

La modificación del entorno social, los horarios de clases, la condición económica y familiar son los principales factores que influyen en la conducta alimentaria de los estudiantes universitarios y por ende inciden en su rendimiento académico.

Para combatir con esta problemática varios investigadores se han enfocado en realizar estudios sobre los sistemas automáticos de monitoreo de la ingesta de alimentos, utilizando aplicaciones IoT.

El objetivo del presente trabajo de integración curricular es ofrecer un análisis de los parámetros que se utilizan para identificar las diferentes actividades tales como: la masticación, deglución y el tipo de comida que se ingiere, con el uso de aplicaciones IoT. Además, se plantea una propuesta para la implementación a futuro de una aplicación que permita el monitoreo de hábitos alimenticios, así como su interrelación con el rendimiento académico de un estudiante.

El trabajo consta de 3 capítulos: el primer capítulo consta del Marco Teórico en el cual se definen algunos conceptos base para el desarrollo del tema, el segundo capítulo la Metodología contiene el análisis de los casos de estudio y se propone una alternativa para una aplicación móvil que pueda ser ejecutada en futuras investigaciones. Finalmente, el tercer capítulo está compuesto de los resultados obtenidos durante el análisis, las Conclusiones y Recomendaciones.

PALABRAS CLAVE: conducta alimentaria, monitoreo, ingesta de alimentos, aplicaciones IoT.

ABSTRACT

The modification of the social environment, class schedules, economic and family conditions are the main factors that influence the eating behavior of university students and therefore affect their academic performance.

For combating this problem, several researchers have focused on conducting studies on automatic food intake monitoring systems, using IoT applications.

The objective of this curricular integration work is offered an analysis of the parameters that are used to identify the different studies such as: chewing, swallowing and the type of food that is ingested, with the use of IoT applications. In addition, a proposal is presented for the future implementation of an application that allows the monitoring of eating habits, as well as its interrelation with the academic performance of a student.

The present work is structured in 3 chapters: Chapter 1 consists of the theoretical framework in which some basic concepts are defined for the development of the topic. In the Chapter 2, the Methodology contains the analysis of the case studies, and the guidelines are proposed to develop an application in a future work. Finally, in the Chapter 3 presents the results obtained during the analysis, the conclusions and recommendations.

KEYWORDS: eating behavior, monitoring, food intake, IoT applications.

1. DESCRIPCIÓN DEL COMPONENTE DESARROLLADO

En los últimos años, en el área de las comunicaciones inalámbricas, sale a la luz un nuevo paradigma denominado IoT (*Internet of Things*), que fue utilizado en 1998 por el pionero británico Kevin Ashton y desde entonces ha llamado la atención de muchas empresas de diferentes sectores (Salud, Industrial, Agrícola, entre otros) [1].

Actualmente los sistemas IoT son aplicados en diferentes áreas y brindan una infinidad de aplicaciones, que prestan nuevos servicios y mejoran la calidad de vida de los usuarios. Estas aplicaciones permiten capturar datos de interés del mundo real y pueden implementarse en dispositivos inteligentes, como, por ejemplo: un reloj inteligente, un dispositivo móvil, una laptop, una tablet, etc [2].

Por otro parte, los estudiantes universitarios en la mayoría de los casos no disponen de adecuados horarios alimenticios, debido a la carga académica y el horario de clases, que influyen negativamente en su rendimiento académico y salud. Gracias a los avances en los sistemas IoT, se pueden implementar aplicaciones que hacen posible mejorar estos hábitos alimenticios, con el propósito de que el estudiante mejore su rendimiento académico y su salud [3][4].

Este proyecto de integración curricular realiza un análisis de las diferentes alternativas que permiten mejorar los hábitos alimenticios, utilizando aplicaciones IoT, en dispositivos móviles. Por lo que la información recopilada es tomada de diferentes estudios publicados en los últimos 5 años, de los cuales se observan enfoques basados en sensores Inertial Measurement Unit (IMU), micrófono y piezoeléctricos. Así como también, se logra evidenciar que cada autor implementa un prototipo diferente que permite el monitoreo de la ingesta de alimentos.

Como se mencionó anteriormente existen algunos estudios que permiten el monitoreo de los hábitos alimenticios, por lo cual es importante extraer los parámetros que se utilizaron en cada caso de estudio, para luego ser clasificados y finalmente ser comparados entre sí.

Este proceso se realiza con la finalidad de definir la técnica de aprendizaje de máquina y los parámetros que se deben tomar en cuenta para la implementación de una futura aplicación que permita monitorear, recopilar y transmitir la información de los hábitos alimenticios, así como su correlación con el rendimiento académico de los estudiantes universitarios.

1.1 Objetivo General

Analizar las alternativas que permitan mejorar el rendimiento académico de los estudiantes universitarios, mediante aplicaciones IoT.

1.2 Objetivos Específicos

1. Estudiar los factores alimentarios que influyen en el rendimiento académico de los estudiantes.
2. Determinar las aplicaciones IoT que permitan monitorear los hábitos alimenticios.
3. Definir las técnicas de aprendizaje de máquina y los parámetros que se utilizan, para la detección de hábitos alimenticios.
4. Presentar alternativas que puedan ser utilizadas a futuro, para monitorear los hábitos alimenticios de estudiantes universitarios, utilizando dispositivos móviles.

1.3 Alcance

En el presente proyecto de integración curricular, se presenta un estudio sobre los factores que influyen en el rendimiento académico de los estudiantes universitarios, dando énfasis en los relacionados con los hábitos alimenticios. Para este análisis, la información es tomada de referencias bibliográficas publicadas en los últimos 5 años y las actividades serán planificadas en base a la metodología de kanban.

Se exponen las alternativas de aplicaciones IoT utilizando dispositivos móviles, que permitan la recopilación de información, su análisis y el comportamiento de variables que inciden en la mejora del rendimiento académico de los estudiantes, por medio del monitoreo de los hábitos alimenticios.

Se definen los parámetros y técnicas de aprendizaje de máquina que pueden ser utilizadas, para inferir los hábitos alimenticios, mediante tablas comparativas.

Finalmente, como resultado de este estudio se define un esquema, que permitirá en un futuro, el desarrollo de una aplicación móvil, que permitirá inferir los hábitos alimenticios de estudiantes universitarios para ayudar a mejorar su rendimiento académico.

1.4 Marco Teórico

1.4.1 Internet de las Cosas (IoT)

El Internet de las Cosas (IoT) se define como la interconexión a través de Internet de dispositivos y sensores incorporados en objetos cotidianos (relojes, teléfonos, televisores, entre otros), que les permite extraer la información necesaria y proporcionar un servicio que facilite la vida diaria del ser humano [2]. Sin embargo, existe una variedad de definiciones de la IoT que enfatizan diferentes aspectos, por ejemplo:

- La Unión Internacional de Telecomunicaciones (UIT) en el 2012, define a IoT como una infraestructura que permite brindar servicios mediante la interconexión de objetos que pueden ser físicos y virtuales gracias a el interfuncionamiento de las tecnologías de la información y comunicación [5].
- En IEEE Communications Magazine explica que IoT es un modelo que ayuda a proporcionar nuevas aplicaciones y servicios mediante la comunicación “máquina a máquina”, que permite las interacciones entre las cosas y los servicios en la nube [2].
- Oxford Dictionaries expone que el Internet de la Cosas es una interconexión a través del Internet de dispositivos y sensores incorporados en objetos cotidianos, que permite la transmisión y recepción de datos [6].

En este caso existen tres diferentes puntos de vista que no son contradictorios a cerca de la definición de la IoT, más bien cada una de estas definiciones destaca diferentes aspectos dependiendo el caso de uso.

1.4.2 Factores que inciden en el rendimiento académico de los estudiantes universitarios

Los hábitos alimenticios son la base fundamental para tener una vida saludable y el motor que permite a nuestro cuerpo realizar diferentes actividades. Tener una buena salud con lleva a que el ser humano pueda desempeñar mejor las actividades tanto físicas como intelectuales.

Las costumbres alimenticias son practicadas desde una corta edad hasta llegar a la adultez; sin embargo, cuando el ser humano es sujeto a cambios en su vida diaria, es posible que estas costumbres puedan modificarse. El caso más frecuente en el que se puede evidenciar lo dicho anteriormente es en los estudiantes universitarios [7].

En la actualidad los estudiantes universitarios son más propensos a desarrollar malos hábitos alimenticios, debido a que no desayunan y ayunan durante largas horas, prefieren la comida rápida alta en grasas o azúcares y no realizan la actividad física necesaria.

En la Tabla 1.1, se detalla los factores que influyen en la alimentación e inciden en el desempeño académico de los universitarios.

Tabla 1. 1 Factores que influyen en la alimentación [8][9].

Factor	Explicación
Modificación del entorno social	La sobrecarga de estudio y la realización de actividades extracurriculares reduce el tiempo en el que el estudiante pueda ingerir alimentos.
Horarios de clase	Los estudiantes tienden a adquirir comida rápida en las “horas huecas” o no ingerir ningún alimento durante día debido a sus estrechos horarios de estudio.
Condición económica	En determinados casos los estudiantes no disponen de una buena situación económica que satisfaga de mejor manera sus necesidades alimentarias.
Familiar	Las universidades del Estado o privadas admiten estudiantes de todas las regiones del Ecuador, por lo que muchos de ellos deben de alejarse de sus familias durante un buen tiempo. Este cambio repentino provoca bajos estados de ánimo en los estudiantes y con ello una mala alimentación.

1.4.3 El impacto del Internet de las Cosas en el sistema alimentario

A medida que la tecnología ha ido evolucionando, el sistema alimentario se ha visto en la obligación de llevar a cabo avances técnicos y científicos, que permitan mejorar la calidad alimentos y bebidas para los consumidores [10]. Por ello, en esta sección se hablará de uno de los avances tecnológicos más importantes referentes a IoT en el sector de la alimentación.

Cada área funcional del sistema alimentario ha mejorado significativamente con la integración de IoT. Por ejemplo, IoT ayuda a las empresas de alimentos a garantizar niveles superiores de trazabilidad, seguridad alimentaria, calidad del producto y empaques.

En la Tabla 1.2, se explica los beneficios más importantes que IoT ofrece en el sistema alimentario.

Tabla 1. 2 Tecnología IoT implementada en cada área del sistema alimentario [12][13].

Área de Aplicación	Beneficios
Logística optimizada y eficiencia operativa	<p>Producción y Procesamiento: IoT se utiliza en la producción de alimentos, ya que permite rastrear y luego predecir el mantenimiento de la maquinaria. Además, tiene la capacidad de monitorear temperaturas, caudales y distribuciones de los ingredientes, mejorando así la calidad del producto.</p> <p>Gestión de almacenes e inventarios: Con la ayuda de sensores, IoT puede monitorear la humedad o la luz solar a la que están expuestos los productos que se encuentran o no almacenados y así lograr un análisis que permita identificar los productos que están en malas condiciones antes de ser vendidos.</p> <p>Empaquetado: IoT logra que el proceso de empaque sea más eficiente ya que verifica el estado del empaque y detiene el proceso si detecta alguna discrepancia.</p>
Trazabilidad y Transparencia	La tecnología IoT rastrea y muestra la información necesaria del origen de los productos y que tan lejos han viajado con el fin de fomentar confianza a los clientes.
Seguridad de alimentos	Debido a la implementación de IoT en el sector alimentario el riesgo de enfermedades alimentarias ha disminuido, ya que utilizan sensores y tecnologías de análisis predictivo basadas en la nube que identifican los patógenos y ayudan a mitigar su propagación.
Reducción de residuos	IoT monitorea el estado de los productos alimenticios y la información es recopilada y enviada en tiempo real a la persona a cargo.

1.4.4 Aplicaciones IoT en el consumo de alimentos

El cambio del estilo de vida de una persona se vuelven complicado al momento de querer llevar una dieta saludable, debido a que la mayoría de las personas consumen comidas

fuera de casa, precocinadas o ultraprocesados en lugar de comidas hechas en el hogar. Por esta razón, varias empresas han creado diferentes plataformas que ayudan a los usuarios a mejorar su alimentación mediante el monitoreo de hábitos alimenticios con el uso de aplicaciones IoT [11]. A continuación, se enlista algunas de las aplicaciones IoT que ayudan a mejorar los hábitos alimenticios.

- *Bixby Vision Food*: permite que los usuarios puedan conocer y guardar la información necesaria de las cantidades de nutrientes que tiene una comida con solo tomarle una fotografía [12].
- *MyFitnessPal*: cuenta las calorías que los usuarios están consumiendo, con el fin de comprender sus hábitos alimenticios y brindar un asesoramiento o consejos de información nutricional [13].
- *Nootric*: ayuda a los usuarios a tener un plan de nutrición con recetas gratis y un seguimiento ajustado [14].
- *MyRealFood*: da a conocer a los usuarios si la comida que están ingiriendo es comida real, comida bien procesada o ultraprocesada, mediante el escaneo de código de barras. Además, dispone de indicador que permite visualizar el consumo de comida real y de comida ultraprocesada [15].
- *sinAzucar.org*: cuenta con un conversor a terrones que ayuda al usuario a saber cuánto de azúcar ingiere al día mediante terrones virtuales que se van añadiendo [16].
- *Aqualert*: recuerda a los usuarios la cantidad de líquidos que deben tomar de acuerdo con su peso y talla [17].

1.4.5 Sensores disponibles en dispositivos móviles

Un sensor es un dispositivo que tiene la capacidad de detectar algún cambio en su entorno (temperatura, humedad, nivel de presión, entre otros) y convertirlo en una señal eléctrica que pueda ser interpretable para los dispositivos electrónicos [18].

Cada vez existe una mayor demanda en los sensores inteligentes debido a que cuentan con circuitos electrónicos integrados y compatibles a los estándares de comunicaciones más comunes en el mundo del Internet de las Cosas [19].

En la Tabla 1.3, se describe algunos de los sensores que permiten el monitoreo de los hábitos alimenticios de una persona.

Tabla 1. 3 Principales Sensores usados para el monitoreo de hábitos alimenticios [23].

Sensor	Funcionalidad	Ubicación
Unidad de Medida Inercial (IMU)	Son sensores de movimiento que están compuestos por un acelerómetro multieje y un giroscopio. El acelerómetro mide la aceleración del dispositivo, mientras que el giroscopio mide el movimiento de rotación del dispositivo. Estos sensores capturan el movimiento del cuerpo en varios ejes y proporcionan características que se utilizan para controlar las actividades alimentarias.	En la parte de la cabeza y en dispositivos basados en la muñeca.
Micrófono	Es un sensor acústico que proporciona las características de audio de la masticación y el sonido de la deglución, que se utilizan para controlar la alimentación.	En collares, dispositivos basados en la muñeca o en dispositivos portátiles ubicados en el oído.
Piezoeléctricos	Son sensores capaces de medir la presión, tensión, aceleración o la fuerza. Las diversas características de las señales de vibración se utilizan para la detección de masticación y deglución, por lo que se utiliza para un monitoreo automático de alimentos.	Detrás del lóbulo de la oreja, en la zona de la cabeza o cuello.

1.4.6 Conceptos básicos de Aprendizaje Automático

El Aprendizaje Automático forma parte de la Inteligencia Artificial, que permite que las computadoras sean capaces de aprender sin estar programadas explícitamente para ello. Su proceso se basa en obtener la información necesaria de grandes cantidades de datos mediante la aplicación de algoritmos que permiten identificar patrones [20].

Dependiendo del enfoque, el Aprendizaje Automático aplica diferentes técnicas que ayudan a aumentar la precisión de los modelos de predicción. En la Figura 1.1, se puede visualizar los tipos de aprendizaje automático con sus respectivos algoritmos.

En la Figura 1.1 [21], se puede observar que existen diferentes clases de algoritmos que el Aprendizaje Automático ofrece. Esta sección se enfocará principalmente en los algoritmos de clasificación, ya que juegan un rol relevante en el monitoreo de los hábitos alimenticios.

Los algoritmos de clasificación tienen como entrada datos de diferentes tipos de señales, que varían en diferentes rangos. La mayoría de los datos se representan en formato numérico, ya que las señales se digitalizan para su procesamiento por la computadora. En otros casos los datos son binarios, por ejemplo, masticar / no masticar, comer / no comer, etc. Y en otros casos los datos pueden definir más de dos clases, por ejemplo, comer mientras camina, comer mientras está sentado, comer mientras está hablando, entre otros.

Por lo tanto, definir un clasificador en especial para el monitoreo de hábitos alimenticios se vuelve impredecible, por lo que, a continuación se definen algunos de los algoritmos de clasificación que son utilizados para monitoreo automático hábitos alimenticios: [22]

- **Support Vector Machine (SVM):** en este algoritmo los datos se dividen en conjuntos de entrenamiento y prueba. SVM se utiliza en datos de gran dimensión, por lo que el tiempo empleado es mayor para grandes bases de datos.
- **Random Forest (RF):** este algoritmo utiliza múltiples árboles de decisión y los resultados de predicción se obtienen mediante el promedio de todos estos árboles utilizados en el cálculo. Random Forest es uno de los que produce mejores predicciones, sin embargo, este algoritmo tiende a sobreajustarse.
- **Neural Networks (NN):** este algoritmo se compone de múltiples nodos, donde cada nodo está conectado a otro con un valor de peso. Neural Networks es útil debido a su alto rendimiento en el cálculo, sin embargo, requieren de más datos de entrenamiento para construir el modelo.

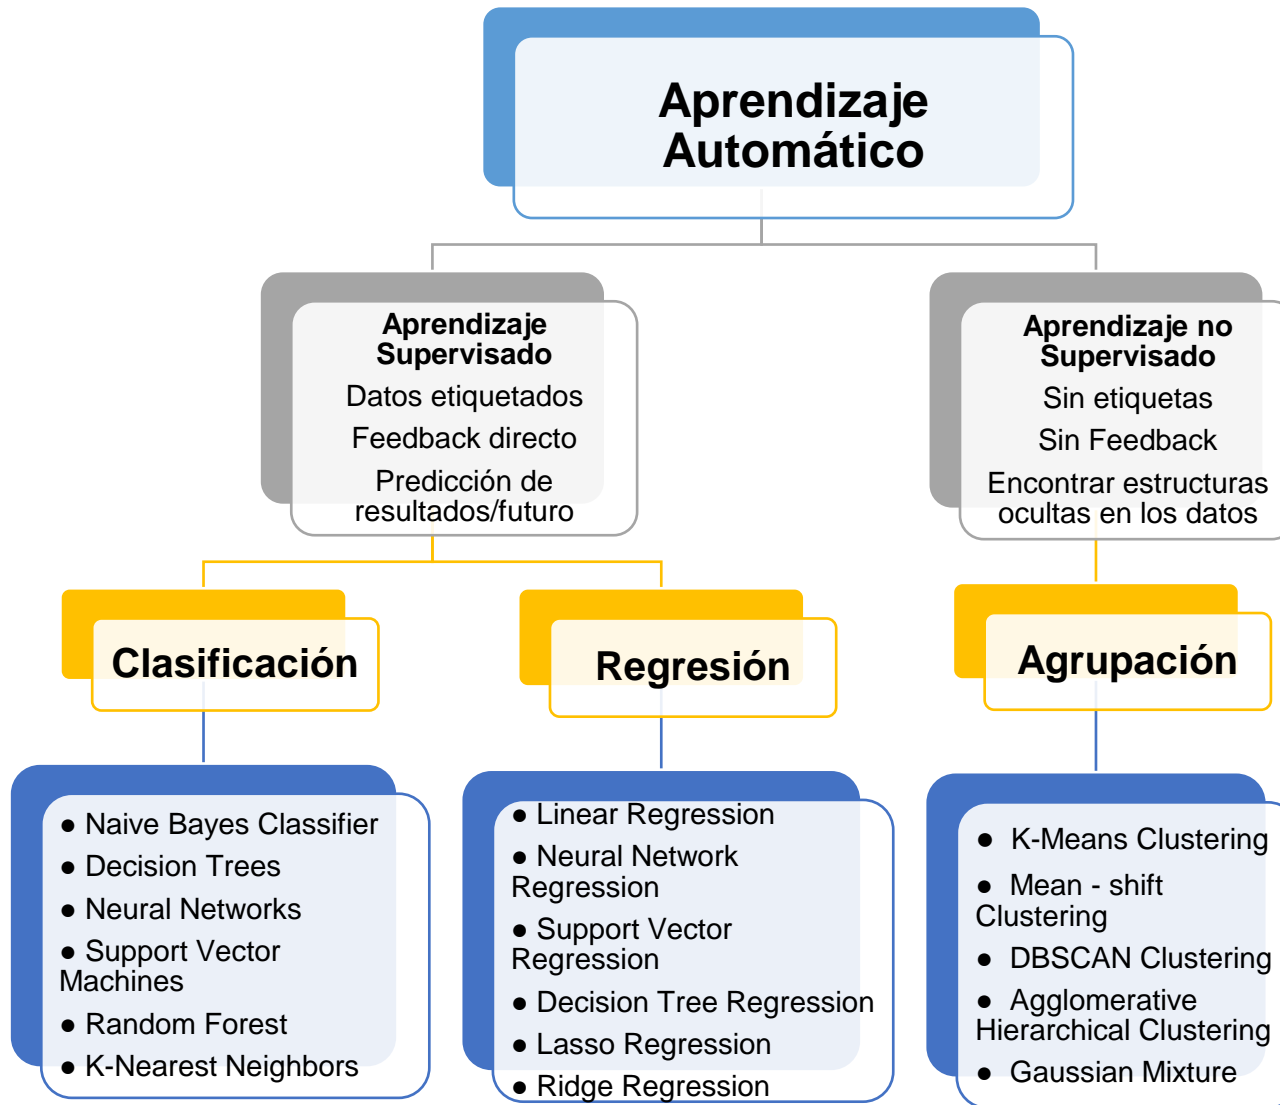


Figura 1. 1 Tipos de Aprendizaje Automático basado en [21]

1.4.7 Indicadores de Rendimiento Académico

El rendimiento académico es un factor fundamental en la educación de un estudiante, ya que mide el nivel de éxito o fracaso que este alcanza en una o más materias. Desde la perspectiva de la educación de tercer nivel, el rendimiento académico se define como el promedio obtenido que tiene cada estudiante en una o más asignaturas durante un periodo de tiempo universitario.

Para evaluar el rendimiento académico de cada estudiante se utiliza diferentes indicadores que dan a conocer si el estudiante tiene un alto o bajo rendimiento. A continuación, definiremos algunos de estos indicadores de rendimiento académico: [23][24]

- **Índice de reprobación de materias:** indica el porcentaje de materias reprobadas por el estudiante en un período académico y se calcula con la Ecuación 1.1:

$$\frac{\# \text{ materias no aprobadas}}{\# \text{ materias aprobadas} + \# \text{ materias no aprobadas}} * 100$$

Ecuación 1. 1 Índice de reprobación de materias

- **Índice de aprobación de materias:** se calcula con la Ecuación 1.2, donde en el numerador se coloca el número de materias aprobadas.

$$\frac{\# \text{ materias aprobadas}}{\# \text{ materias aprobadas} + \# \text{ materias no aprobadas}} * 100$$

Ecuación 1. 2 Índice de aprobación de materias

- **Índice de reprobación de créditos:** indica el porcentaje de créditos reprobadas por el estudiante en un periodo académico y se calcula con la Ecuación 1,3:

$$\frac{\# \text{ créditos no aprobados}}{\# \text{ créditos aprobados} + \# \text{ créditos no aprobados}} * 100$$

Ecuación 1. 3 Índice de reprobación de créditos

- **Índice de aprobación de créditos:** se calcula de la misma forma descrita en la Ecuación 3, solo que en el numerador se coloca el número de créditos aprobadas, como se muestra en la Ecuación 1.4.

$$\frac{\# \text{ créditos aprobados}}{\# \text{ créditos aprobados} + \# \text{ créditos no aprobados}} * 100$$

Ecuación 1. 4 Índice de aprobación de créditos

- **Índice de rendimiento académico (IRA):** es la multiplicación del promedio ponderado de calificaciones (PPC) y el coeficiente de aprobación (CA):

$$IRA = PPC * CA$$

Ecuación 1. 5 Índice de rendimiento académico

- **Promedio ponderado de calificaciones (PPC):** es la sumatoria del producto entre la nota final de cada materia aprobada por el número de créditos de las materias aprobadas, dividida para la sumatoria de los créditos totales de las materias aprobadas.

$$PPC = \frac{\sum_{i=1}^n \text{calificación final } i * \# \text{ créditos } i}{\sum_{i=1}^n \# \text{ créditos } i}$$

Ecuación 1. 6 Promedio ponderado de calificaciones

- **Coeficiente de aprobación (CA):** es la división entre el número créditos totales aprobados sobre el total de créditos registrados por el estudiante, incluyendo número de veces en las que reprobó.

$$CA = \frac{\# \text{ total de créditos aprobados}}{\# \text{ total de créditos matriculados}} * \# \text{ de veces reprobados}$$

Ecuación 1. 7 Coeficiente de aprobación

2. METODOLOGÍA

Para el desarrollo del presente trabajo de integración curricular se utiliza como base principal la metodología Kanban, que permite visualizar la carga y el flujo organizado del trabajo de integración curricular. El tablero kanban es una herramienta utilizada para trabajos en equipo. Sin embargo, debido a que el desarrollo del componente es individual, dicha herramienta será aplicada para uso personal con el fin de dar un seguimiento a las tareas semanales. Las 12 tareas a ser desarrolladas fueron tomadas del plan de trabajo presentado.

El enfoque del trabajo es cualitativo, ya que se recolecta la información necesaria de varios estudios referentes al monitoreo de hábitos alimenticios mediante la utilización de diferentes tipos de sensores. Como ya se explicó anteriormente para iniciar la elaboración del presente trabajo se implementó un tablero Kanban sintetizado, donde constan todas las tareas que se encuentran “Pendientes”, “En proceso” y “Finalizadas”, con la finalidad que maximicen la eficiencia de este. En la Figura 2.1 se presenta el tablero kanban implementado en la elaboración de las tareas de la primera y segunda semana del capítulo 1.

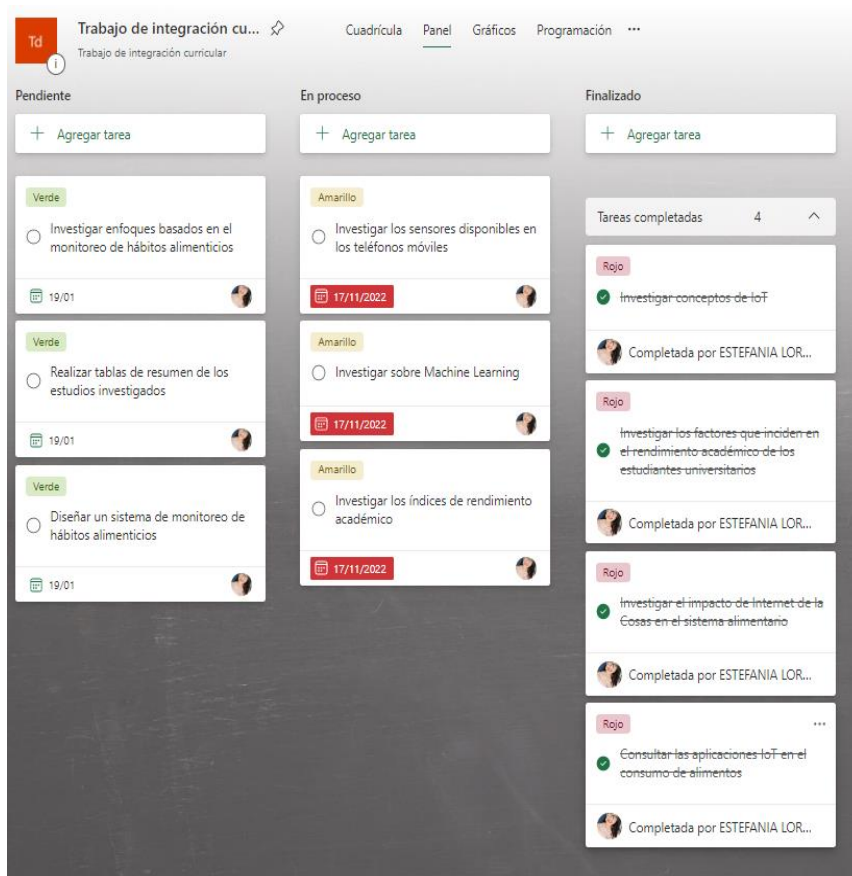


Figura 2. 1 Metodología Kanban

El trabajo implementado se basa en casos de estudio, basados en diferentes enfoques, empleando un análisis documental como técnica de recopilación de información. La información recolectada se obtiene a través de diferentes motores de búsqueda tales como IEEE Xplore, Google Scholar y de páginas web de proyectos fiables. Además, dicha información será basada en publicaciones realizadas dentro de los últimos 5 años.

2.1 Casos de Estudio

Los casos de estudio investigados sobre el monitoreo de la ingesta de alimentos se pueden clasificar según el número y el tipo de sensores. A continuación, para esta sección se detallan los enfoques basados en los sensores IMU, micrófono y piezoeléctricos.

2.1.1 Enfoques basados en sensores IMU

- **CASO DE ESTUDIO 1:** Modelo de detección de acciones alimenticias mediante pulseras [25].

Este estudio propone una metodología llamada IDEA (*Instant Detection of Eating Action*). El proceso en el cual se identifica la acción comer se lleva a cabo en dos simples pasos:

El primer paso se basa en un Modelo Generalizado que implica la aplicación de DNN (*Deep Neural Networks*) sobre instancias de usuarios individuales, para clasificar las acciones de comer, durante las cuales se separan las acciones no confirmadas, es decir, no se identifica la acción.

El segundo paso se denomina Modelo Personalizado, se utilizan patrones de alimentación similares como conjunto de entrenamiento para clasificar aún más las instancias no confirmadas.

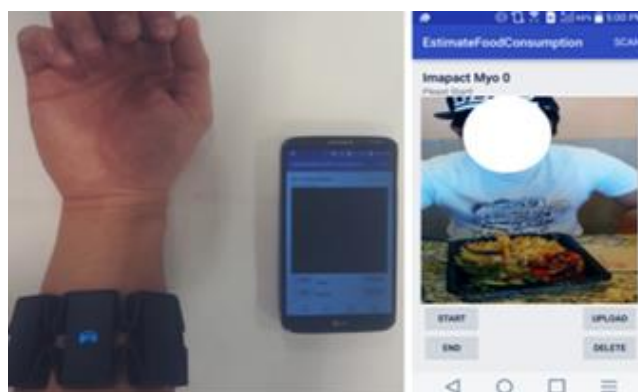


Figura 2. 2 Prototipo del caso de estudio 1 [25]

El prototipo IDEA utiliza dos dispositivos: un teléfono inteligente y una pulsera Myo que incluye cuatro juegos de sensores: acelerómetro (ejes X, Y y Z), giroscopio (ejes X, Y y Z), orientación (ejes W, X, Y y Z) y electromiograma.

La metodología se probó con 36 participantes, con una pulsera y arrojó una puntuación F1 del 92%, que representa un alto rendimiento. En la figura 2.2 se puede visualizar el prototipo basado en IDEA.

- **CASO DE ESTUDIO 2:** Estudio de fallos en la ejecución de los modelos en la detección alimenticia [26].

Este estudio fue aplicado en un entorno libre utilizando un sensor inercial de muñeca, como se muestra en la Figura 2.3. Su proceso se adaptó a un enfoque de dos etapas para detectar el consumo de alimentos.

La primera etapa se basa en la detección de movimiento y el período descanso de los individuos se separa de otras actividades. Se utiliza un clasificador de alta recuperación para identificar los períodos de descanso.

La siguiente etapa es la detección de alimentación, ésta se adapta a un enfoque MTFC (*Motif-Based Time Fusion Classifier*), que permite detectar los gestos de alimentación mediante dos componentes principales. El primer componente busca motivos para generar un conjunto de candidatos, y el segundo componente trabaja para la clasificación de candidatos. El ruido de los puntos de datos se elimina aplicando un núcleo gaussiano, y para clasificar los gestos de alimentación y no alimentación se utiliza el algoritmo RF (*Random Forest*).



Figura 2. 3 Prototipo del caso de estudio 3 [26]

La metodología se probó en 8 participantes durante 1920 minutos de datos recolectados para los experimentos. Los resultados indicaron un 90% de recuperación y un 61% de F1. El porcentaje F1 es bajo mientras que el porcentaje de recuperación es alto, esto indica que la metodología es vulnerable a falsos positivos, lo que requiere más investigación con un gran conjunto de datos.

- **CASO DE ESTUDIO 3:** Medición del comportamiento alimentario mediante un reloj inteligente [27].

El estudio presenta un enfoque para detectar eventos de alimentación utilizando sensores IMU, en relojes inteligentes. En este enfoque, las señales se suavizan utilizando un filtro FIR (*Finite Impulse Response*) de paso alto. El siguiente paso implica la clasificación utilizando dos redes CNN (*Convolutional Neural Networks*) y LSTM (*Long Short – Term Memory STM*).

La metodología se probó con 10 participantes en 10 sesiones de comida. Se logró un 85% de precisión, un 92% de recuperación y un 80% de puntuación F1 para la detección de eventos de alimentación, en un ambiente de laboratorio.

- **CASO DE ESTUDIO 4:** Modelado de micromovimientos de muñeca para medir el comportamiento alimentario [28].

Los autores comienzan con una breve definición de la ingesta de alimentos y explican que se trata de una secuencia de micromovimientos de la muñeca que consiste en recoger alimentos, subir, bajar, sin movimiento, entre otros. Para este estudio se utilizó sensores inerciales.

El primer paso del proceso consiste en que las señales se preprocesan utilizando un filtro FIR. A continuación, se utiliza una CNN para estimar los micromovimientos en cada ventana del flujo del sensor y se utiliza LSTM para clasificar el consumo de alimentos.

La metodología se probó con 12 sujetos en 21 sesiones de comida y fue capaz de identificar ciclos de alimentación con un 90% de precisión, un 93% de recuperación y un 91% de puntuación F1. Sin embargo, la metodología requiere que se conozcan los momentos de inicio/ finalización de las comidas.

- **CASO DE ESTUDIO 5:** Detección de comida usando un reloj inteligente [29].

Este estudio tiene como objetivo detectar la masticación en un entorno no controlado, en tiempo real y utilizando relojes inteligentes. Su proceso se basa en dos pasos.

En el primer paso, el flujo de datos recopilados del acelerómetro y el giroscopio se filtra para eliminar diferentes tipos de ruidos en los datos. En el siguiente paso, los datos se segmentan para crear ventanas deslizantes de 15 segundos. Se obtiene valores de baja precisión usando RF y las predicciones se suavizan usando HMM (*Hidden Markov Model*).

La metodología se probó con 10 participantes en 70 comidas diferentes y 161 horas de actividades diferentes en condiciones de vida real no controlada. El enfoque fue capaz de lograr un 70% de precisión y un 83% de recuperación, siendo inferior a otros enfoques similares basados en la muñeca.

Aunque la metodología se prueba en un entorno real no controlado, es necesario mejorar el número de falsos positivos (baja precisión).

- **CASO DE ESTUDIO 6:** Sistema de monitoreo de hábitos alimenticios utilizando una pulsera [30].

En esta propuesta se usaron sensores inerciales en muñequeras para clasificar las actividades de comer. Su funcionamiento se basa en recibir los valores del eje del acelerómetro y el giroscopio, mientras que el ángulo de rotación de 3 ejes se denomina movimiento de mordida. También se utilizó una herramienta llamada Blueinno2 para la detección de la mordedura, esta herramienta recibe datos de MPU-6050 a través de I2C (*Inter Integrated Circuit*) sobre los valores de los ejes x, y, z del acelerómetro y el giroscopio.

En base los datos obtenidos, se calcula el movimiento de la muñeca. Si uno de los ejes x, y, z del movimiento de la muñeca gira más de ± 70 grados/s durante 200 ms, se determina como el movimiento de una mordida.

En la Figura 2.4 se muestra el prototipo con sus componentes: Batería de monedas (1), Adaptador de batería (2), MPU-6050 (acelerómetro/giroscopio) (3), Blueinno2 (4), Motor de vibración (5), Cuerpo mediante impresión 3D (6), Correa para muñeca (7).



Figura 2. 4 Prototipo del caso de estudio 6 [30]

- **CASO DE ESTUDIO 7:** CARE (Chewing Activity Recognition) utilizando un acelerómetro de un solo eje no invasivo [31].

Es un estudio basado en un acelerómetro de un eje, ubicado en el músculo temporal de la masticación. Los datos obtenidos por los sensores se pasan a una aplicación móvil para la identificación de masticación.

El primer paso del proceso de detección es la extracción de características en el dominio del tiempo y de la frecuencia. Estas características luego se pasan al proceso de clasificación, donde se implementan 5 algoritmos de clasificación. Los algoritmos incluyen DT (*Decision Tree*), MLP (*Multi-Layer Perceptron*), SVM (*Support Vector Machine*), NN (*Nearest Neighbor*) y WSVM (*Weighted SVM*).

La metodología se probó con el sensor Shimmer, los datos se recopilaron durante 150 minutos en diferentes actividades con 4 participantes. Según los autores, el clasificador WSVM proporciona un rendimiento equilibrado con un 96% de exactitud, un 91% de precisión, un 92% de recuperación y un 91% de puntuación F1.

- **CASO DE ESTUDIO 8:** Reconocimiento de ingesta de comida con sensores inerciales en la muñeca [32].

Este estudio utiliza un sensor inercial para reconocer la alimentación en entornos controlados y no controlados. En el primer paso, los datos del sensor del acelerómetro de 3 ejes se reciben de un reloj inteligente. Los datos obtenidos se filtran mediante un filtro de EMA (*Exponentially-Weighted Moving Average*) y los fotogramas se extraen de la transmisión. Para cada cuadro, se extraen diferentes características y se pasan al proceso de clasificación de ingesta de alimentos.

El algoritmo RF se utiliza para la clasificación de los gestos de ingesta de alimentos. Como se puede observar en la Figura 2.5, se realizan tres estudios para probar el enfoque, es decir, 20 participantes con condiciones de laboratorio semicontroladas, 7 participantes en condiciones salvajes (un día) y 1 participante en condiciones salvajes prolongadas (31 días). Se define a condiciones salvajes como el entorno de prueba donde surgen obstáculos que no pueden ser controlados e influyen en los resultados.

En el segundo estudio con 7 participantes en condiciones salvajes arrojó una puntuación F1 del 76%, mientras que el tercer estudio con 1 participante en condiciones salvajes prolongadas se arrojó una puntuación F1 del 71%. La precisión en ambos casos ronda el 65%.

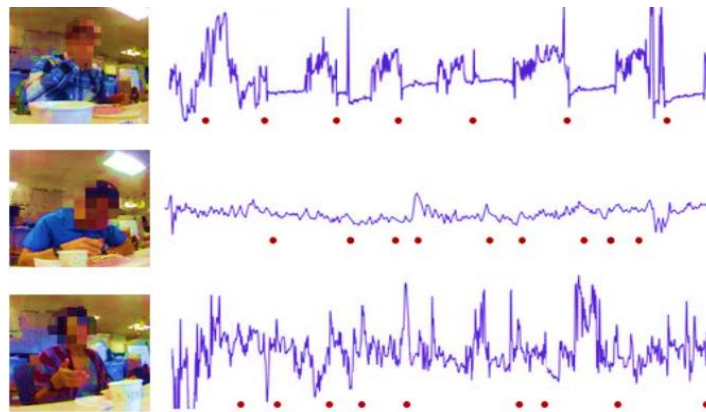


Figura 2. 5 Recolección de datos del caso de estudio 8 [32]

- **CASO DE ESTUDIO 9:** Reconocimiento no intrusivo de comida usando Google Glass [33].

En este estudio se propone usar el movimiento de la cabeza para detectar acciones de comer. Para cumplir con este propósito, utilizaron Google Glass para capturar el movimiento con un acelerómetro y un giroscopio integrados.

En la Figura 2.6, se visualiza el proceso que cumple este estudio. En el primer paso, se reciben los datos de los sensores y se extraen varias características. A continuación, se pasan al módulo de clasificación KNN, NB, C45 y RF. Esta metodología fue probada con 38 participantes, quienes realizaron una serie de actividades como comer, beber, caminar y hablar, etc. en un ambiente controlado.



Figura 2. 6 Representación de reconocimiento de actividad [33]

Los resultados destacaron que la metodología es capaz de lograr una puntuación F0.5 del 67% con RF. Una inspección más detallada de los resultados de precisión de RF reveló que la metodología no detectó la alimentación del 24% de los participantes, mientras que la precisión está entre el 40% y el 80% para el 40% de los participantes. Estos resultados muestran que el sistema se comporta de manera inestable en ambiente controlado.

- **CASO DE ESTUDIO 10:** Detección de gestos alimenticios mediante el movimiento de los dedos [34].

Se enfoca en el uso de un acelerómetro de 3 ejes y un giroscopio montado en un anillo para capturar los datos inerciales, con el fin de detectar el consumo de alimentos.

Los datos recibidos se segmentan y las 22 características de los datos se pasan al proceso de clasificación para categorizar entre comer o no comer, utilizando algoritmos que incluyen SVM, NB, KNN, RF, DT, NN y Log. R.

La metodología se prueba con un sensor montado en un anillo y un sensor de muñeca, como se muestra en la Figura 2.7. El número de sujetos se desconoce; sin embargo, los gestos informados cuentan hasta 375. KNN funciona mejor que otros algoritmos con un 91% de precisión.




Figura 2. 7 Prototipo del caso de estudio 10 [34]

- **CASO DE ESTUDIO 11:** Detección de episodios alimenticios utilizando un sensor inercial en la mandíbula [35].

El estudio se basó en un sensor inercial conectado en la parte inferior de la mandíbula para la detección de alimentos, como se muestra en la Figura 2.8. Las ventanas de 4 segundos se consideran masticación, mientras que las ventanas de 20 segundos se consideran ataques de masticación, y un grupo de ataques de masticación dentro de los 2 minutos se denomina episodio de alimentación.

En el primer paso, los datos se normalizan con una medida de puntuación z y se definen ventanas de 4 segundos. El siguiente paso, implica la extracción de características y para la detección de alimentos se usa el clasificador de RF.

La metodología se probó con 14 participantes, la precisión para tres tipos de detecciones fue superior al 80 %; sin embargo, la recuperación fue del 47% para la detección de masticación en condiciones de laboratorio. La detección de episodios de alimentación en condiciones salvajes (alimentación dentro de un período de 6 horas en donde los participantes realizaron una variedad de actividades como: realizar tareas informáticas y hablar por el teléfono) tuvo una precisión del 92% y una recuperación del 89%. Las diferencias sustanciales entre diferentes medidas en diferentes condiciones sugieren que el enfoque debe probarse con una población más grande. Además, la posición incómoda del sensor no es natural en general.



Figura 2. 8 Prototipo del caso de estudio 11 [35]

- **CASO DE ESTUDIO 12:** Detección de conteo de masticaciones a través de las contracciones del músculo de masticación [36].

Es un estudio basado en un acelerómetro ubicado en la cabeza, para detectar la contracción muscular, como se muestra Figura 2.9. El trabajo incluye detección de actividad alimenticia y detección de conteo de masticaciones. El ruido de las señales se elimina utilizando un filtro mediano, mientras que la segmentación implica una operación de ventana deslizante. Posteriormente, se extraen 23 características de la señal, que se normaliza mediante el algoritmo de z-score. En el siguiente paso se aplica 5 algoritmos de clasificación DT, NN, MLP, SVM y WSVM que detectan la actividad alimentaria de otras actividades como hablar, sentarse, pararse, caminar, beber y toser.

La metodología se aplicó a 4 sujetos en condiciones controladas y se obtuvo como resultados que la precisión promedio de los algoritmos un 94% y la puntuación F1 fue del 87% para la detección de masticación. El algoritmo de conteo de masticación proporcionó un error promedio del 12%. Los resultados son alentadores, sin embargo, debido al pequeño tamaño del conjunto de datos, el enfoque requiere más pruebas en el entorno natural.

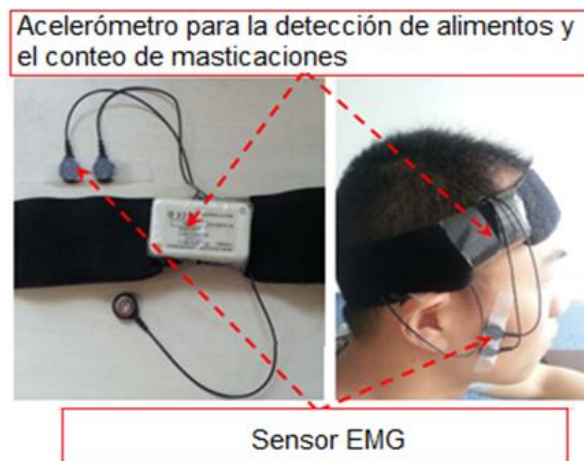


Figura 2. 9 Prototipo del caso de estudio 12 [36]

2.1.2 Enfoques basados en sensor micrófono

- **CASO DE ESTUDIO 1:** iHear Food [37].

El estudio se basa en la utilización de auriculares Bluetooth con sensor micrófono incluido para la detección de masticación, como se muestra en la Figura 2.10.

Los autores argumentan que masticar los alimentos más duros genera más sonido en comparación con alimentos blandos; por lo tanto, estos patrones de sonido son útiles para determinar el tipo de alimento. El audio recibido se procesa para crear segmentos más cortos, y las características de dominio de tiempo y frecuencia se extraen de las señales. Finalmente, se utiliza los clasificadores SVM y RBM (Restricted Boltzmann Machine).




Figura 2. 10 Prototipo del caso de estudio 13 [37]

La metodología se probó con 28 participantes, que realizaron actividades como comer, hablar y beber. El clasificador SVM pudo alcanzar entre un 94%-95% de exactitud en entornos de laboratorio y hasta entre un 65%-76% de exactitud en un entorno libre. El clasificador RBM logró una exactitud entre 77%- 94% en el entorno natural.

- **CASO DE ESTUDIO 2:** Detección de masticaciones utilizando un micrófono en el oído [38].

Este estudio se basa en un micrófono de oído que permite detectar la masticación. En el primer paso del proceso, se aplica un filtro paso bajo a las señales de audio para reducir el muestreo a frecuencias más bajas, seguido de un filtro paso alto FIR para eliminar las frecuencias muy bajas. CNN se aplica a los datos para clasificar las instancias como masticables o no masticables.

Esta metodología se probó con 14 participantes en un entorno semi libre con datos de 60 horas. La metodología proporcionó más del 95% de precisión; mientras que la puntuación F1 se calculó en un 88%. Los resultados sugieren que el enfoque puede probarse aún más en un entorno libre.

- **CASO DE ESTUDIO 3:** AutoDietary [39].

El objetivo de este estudio es capturar sonidos mientras se está ingiriendo alimentos, a través de un sensor que se usa alrededor del área del cuello, como se muestra en la Figura 2.11.

En el primer paso del proceso, se realiza la amplificación y filtración para asegurar una mejor calidad de las señales. Posteriormente, se utiliza HMM para detectar la masticación y la deglución. Para la clasificación del tipo de alimento se utiliza el clasificador DT.




Figura 2. 11 Prototipo del caso de estudio 15 [39]

La metodología se probó con 12 personas. La precisión de masticación/deglución fue calculado como 87%, mientras que la precisión de clasificación del tipo de alimento produjo un 87% de exactitud, un 88% de recuperación, un 86% de precisión y un 87% F1. Aparte de esto, el puntaje F1 del 100% (redondeado) fue informado para la clasificación de alimentos líquidos y sólidos. Sin embargo, los experimentos se llevaron a cabo únicamente en condiciones de laboratorio.

- **CASO DE ESTUDIO 4:** Clasificación robusta de los sonidos al comer [40].

El estudio utiliza un método para clasificar los datos de alimentación, recopilados en forma de sonidos recibidos de un sensor micrófono. Se aplica algoritmos de DT, SVM y NN.

La metodología se probó en 9 participantes en un entorno libre mediante la recopilación de datos durante 95 minutos. Los resultados obtenidos revelaron que SVM proporciona una mejor exactitud igual al 97% en comparación con los otros algoritmos. La exactitud del algoritmo disminuyó al 95% con 7 funciones, mientras que al usar 14 funciones la exactitud fue de 92%. Los resultados de precisión y

recuperación no están disponibles para evaluar más a fondo el enfoque debido a que la SVM es generalmente sensible al desequilibrio de clases.

2.1.3 Enfoques basados en sensores piezoeléctricos

- **CASO DE ESTUDIO 1:** Medición automática del conteo de masticaciones durante la ingesta de alimentos [41].

En este estudio se utilizó un sensor piezoeléctrico detrás del lóbulo de la oreja para la detección y cuantificación de la masticación, como se muestra en la Figura 2.12. Se aplica un algoritmo ANN de masticación en los episodios de alimentación para cuantificar los recuentos de masticación.

La metodología se probó en 30 participantes. El enfoque resultó en 91% F1-Score para la clasificación ANN.




Figura 2. 12 Prototipo del caso de estudio 17 [41]

- **CASO DE ESTUDIO2:** Reconocimiento de la ingesta de nutrientes mediante un sensor piezoeléctrico en un collar [42].

Los autores diseñaron un collar con un sensor piezoeléctrico junto con una aplicación de teléfono inteligente, como se muestra en la Figura 2.13. En este estudio se utilizan los algoritmos de detección de deglución a través de KNN, Red Bayesiana y Bosque Aleatorio.

La metodología se probó en 10 personas con RF y se obtuvo un 94% de precisión mejor que los otros algoritmos.



Figura 2. 13 Prototipo del caso de estudio 18 [42]

- **CASO DE ESTUDIO 3:** Reconocimiento de la ingesta de alimentos y la actividad física [43].

Se propuso un sensor de tensión piezoeléctrico y un acelerómetro. El sensor de tensión piezoeléctrico se coloca en el músculo temporal y el acelerómetro se coloca en los anteojos, como se muestra en la Figura 2.14. El primer enfoque combina las características de ambos sensores para crear un solo vector al que se aplica SVM.

El otro enfoque funciona en dos pasos. El primer paso usa dos clasificadores donde el primer clasificador es un SVM que detecta la ingesta de alimentos usando señales de sensores piezoeléctricos y el segundo clasificador un SVM que usa señales de acelerómetro para diferenciar entre las categorías de caminar y descanso.

La metodología se probó en 10 participantes, el primer enfoque dió como resultado un puntaje F1 promedio del 95,7 %, mientras que en el segundo enfoque se obtuvo como resultado un puntaje F1 promedio del 99,85 %.



Figura 2. 14 Prototipo del caso de estudio 19 [43]

- **CASO DE ESTUDIO 4:** Detección de masticación mediante sensores piezoeléctricos [44].

Se realizó con 3 sensores para la detección de alimentos, un sensor piezoeléctrico (conectado a la oreja), un sensor de gestos de mano a boca (ubicado en la muñeca) y un acelerómetro triaxial (ubicado en el cuello).

Los autores aplicaron DT, LDA (Latent Dirichlet Allocation) y regresión logística con fines de clasificación.

La metodología se probó en 12 sujetos, en condiciones de vida libre. La mayor precisión lograda fue utilizando LDA Classifier con un F1 del 93 %, mientras que los valores de precisión y recuperación se situaron en el 97 % y el 90 %.

En la Tabla 2.1, Tabla 2.2 y Tabla 2.3, se observa un resumen detallado de los tres enfoques basados en sensores IMU, micrófono y piezoeléctrico, respectivamente. En cada caso se clasificó según los sensores utilizados, la ubicación, el algoritmo, el número de personas de prueba, el ambiente en el cual se realizó el estudio; además cada enfoque proporcionó diferentes parámetros de medición como Exactitud, Precisión, Recuperación y F1.

Tabla 2. 1 Enfoques basados en sensores IMU

Estudio	Sensor	Ubicación	Algoritmo	# Personas	Ambiente	Exactitud	Precisión	Recuperación	F1
[25]	acelerómetro giroscopio orientación electromiograma	muñeca	DNN	36	-	-	-	-	92%
[26]	inercial	muñeca	RF	8	libre	-	-	90%	61%
[27]	inercial	muñeca	CNN y LSTM	10	laboratorio	-	85%	92%	80%
[28]	inercial	muñeca	CNN y LSTM	12	libre	-	90%	93%	91%
[29]	acelerómetro giroscopio	muñeca	HMM	10	libre	-	70%	83%	76%
[30]	acelerómetro giroscopio	muñeca	-	15	laboratorio	97%	95%	-	-
[31]	acelerómetro	músculo temporal	WSVM	4	-	96%	91%	92%	91%
[32]	acelerómetro	muñeca	RF	7 (1 día) 1(31 días)	-	-	67%	89%	76% 71%
[33]	acelerómetro giroscopio	ojos	RF	38	laboratorio	-	-	-	67% (0.5)
[34]	acelerómetro de 3 ejes y giroscopio	mano	KNN	-	-	-	91%	-	-
[35]	inercial	mandíbula	RF	14	laboratorio libre	-	80%+ 92%	47% 89%	-
[36]	acelerómetro	cabeza	DT, NN, MLP, SVM y WSVM	4	laboratorio	-	94%	-	87%

Tabla 2. 2 Enfoques basados en sensores de micrófono

Estudio	Sensor	Ubicación	Algoritmo	# Personas	Ambiente	Exactitud	Precisión	Recuperación	F1
[37]	micrófono	oreja	SVM RBM	28	laboratorio libre libre	94%-95% 65%-76% 77%-94%	-	-	-
[38]	micrófono	oreja	CNN	14	libre	95%	-	-	88%
[39]	micrófono	cuello dif. alimento líquido sólido	DT	12	laboratorio	87% 100% 100%	86% 100% 100%	88% 100% 100%	87% 100% 100%
[40]	micrófono	cabeza	SVM	9	libre	97%	-	-	-

Tabla 2. 3 Enfoques basados en sensores piezoeléctricos

Estudio	Sensor	Ubicación	Algoritmo	# Personas	Ambiente	Exactitud	Precisión	Recuperación	F1
[41]	piezoeléctrico	oreja	ANN	30	-	-	-	-	91%
[42]	piezoeléctrico	cuello	RF	10	-	-	94%	-	
[43]	piezoeléctrico acelerómetro	músculo temporal ojos	SVM	10	laboratorio libre	-	-	-	95.7% 99.85%
[44]	piezoeléctrico acelerómetro	oreja muñeca cuello	LDA	12	libre	-	97%	90%	93%

2.2 Sistema automático para monitoreo de hábitos alimenticios

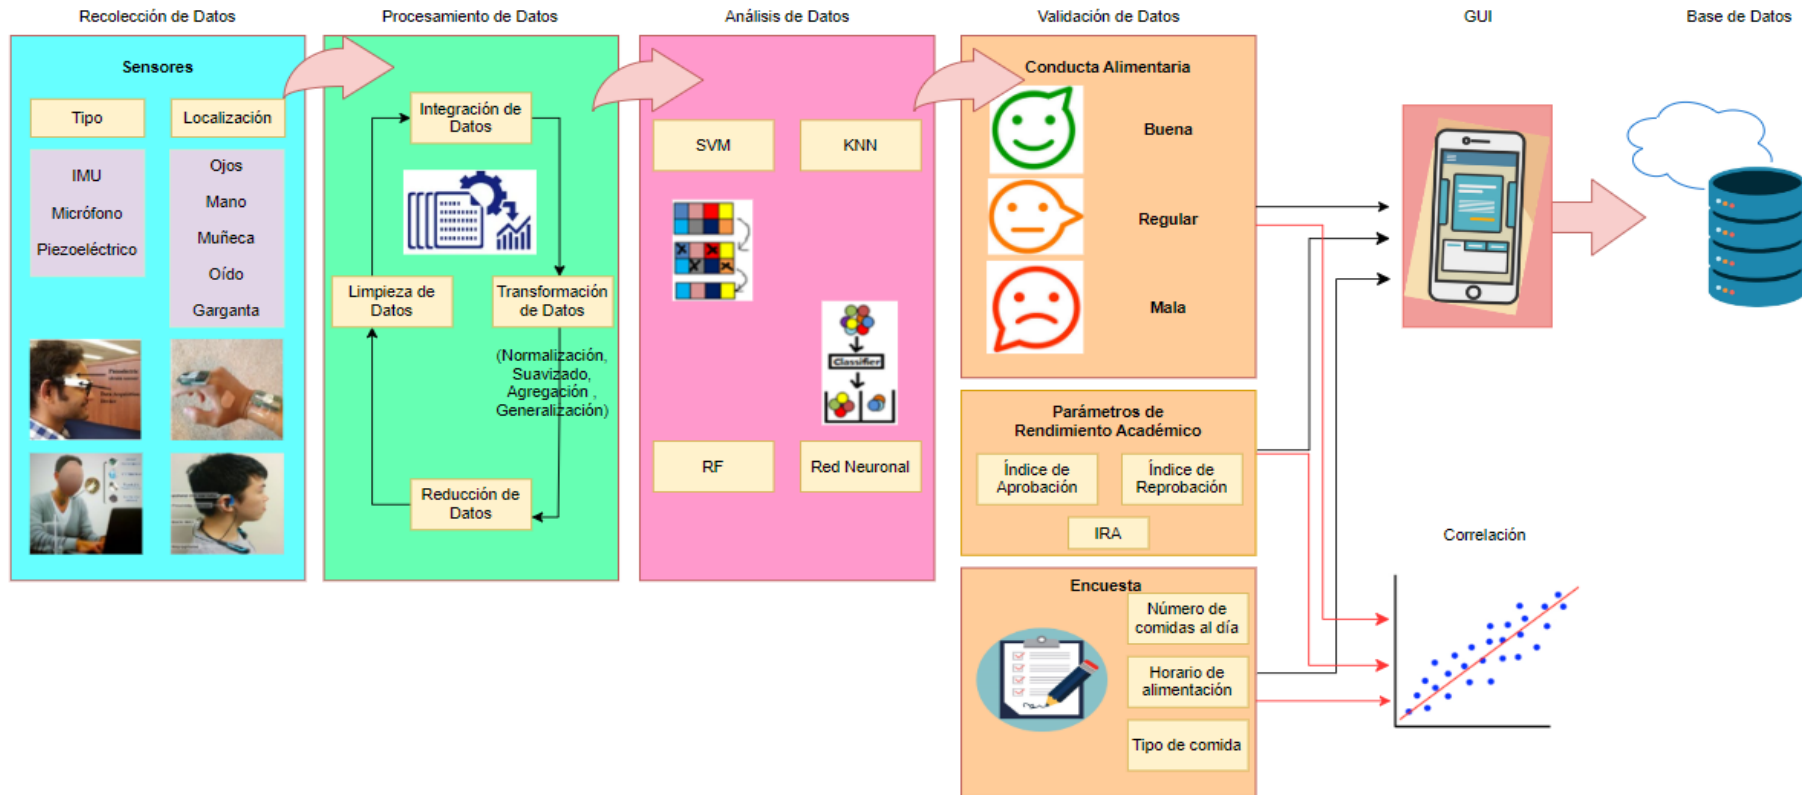


Figura 2. 15 Sistema automático de monitoreo de hábitos alimenticios

En esta sección se define los conceptos relacionados con la propuesta de un sistema automático de monitoreo, como se puede observar en la Figura 2.15. Se presentan las cuatro fases que describen el funcionamiento de un sistema automático de monitoreo de hábitos alimenticios, junto con los parámetros de rendimiento académico y la conducta alimentaria obtenida a través de formularios. Todos los valores obtenidos se pueden correlacionar y guardar en la nube/repositorio físico. A continuación, se describen estas fases.

- **Fase 1:** Recolección de Datos

El proceso comienza con la recolección de datos, como se observa en la Figura 2.16. esta fase se utiliza para guardar los datos que se obtienen de los sensores. Los principales sensores son de tipo IMU, micrófono y piezoeléctrico, mismos que se encuentran ubicados en diferentes partes de cuerpo.



Figura 2. 16 Fase 1: Recolección de Datos

- **Fase 2:** Procesamiento de Datos

En la segunda fase se encuentra el procesamiento de Datos, como se observa en la Figura 2.17, que incluye cuatro pasos que permiten coseguir una información utilizable.

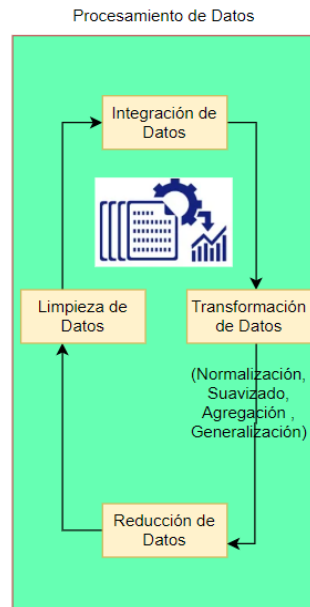


Figura 2. 17 Fase 2: Procesamiento de Datos

1. **Limpiar los datos:** consiste en identificar y eliminar los datos que son inconsistentes.
 2. **Integración de datos:** permite combinar los datos desde varias fuentes.
 3. **Transformación de datos:** en este paso se involucra la normalización, el suavizado, la agregación y la generalización.
 - **Normalización:** permite que los atributos se encuentren en un rango pequeño como entre -1 y 1 o 0 y 1.
 - **Suavizado:** elimina el ruido de los datos.
 - **Agregación:** es una operación que se aplica a los datos.
 - **Generalización:** trata de reemplazar los datos de bajo nivel por datos de más alto nivel.
 4. **Reducción de datos:** permite tener una representación de datos más detallada sin perder la integridad de los datos originales [45].
- **Fase 3: Análisis de Datos**

La tercera fase es la de análisis de datos (Figura 2.18), debido a que no todas las características de una base de datos son fundamentales para la clasificación, se aplican algoritmos de selección, que permitan limitar las características a un grupo más pequeño.

Los algoritmos de clasificación más utilizados según los casos de estudio investigados son SVM, KNN, RF, Red Neuronal.

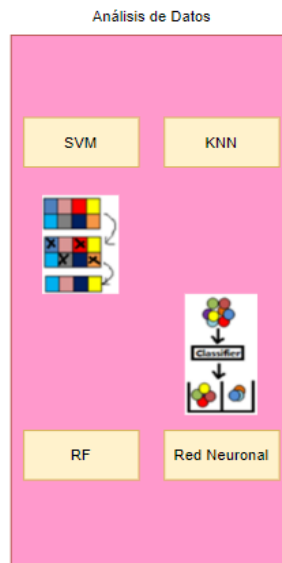


Figura 2. 18 Fase 3: Análisis de Datos

- **Fase 4:** Validación de Datos

Por último, se tiene fase de validación de datos (Figura 2.19), en esta fase se obtienen los resultados arrojados por el algoritmo; así como también, los valores que se obtienen a través de la creación de formularios de rendimiento académico y de la conducta alimentaria.

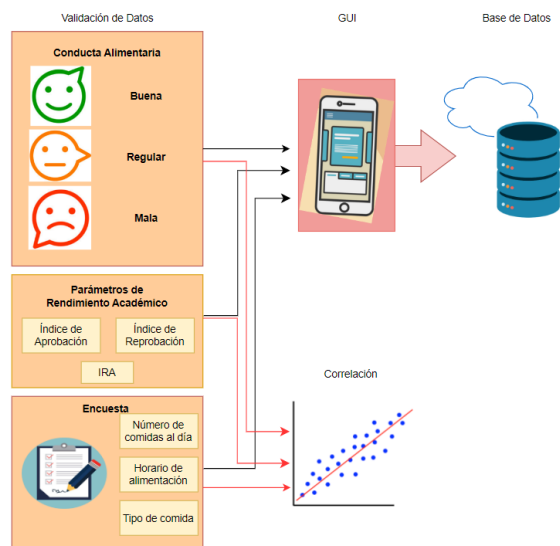


Figura 2. 19 Fase 4: Validación de Datos

Todos los resultados son mostrados en una GUI (interfaz gráfica de usuario). Tanto resultados como valores ingresados serán almacenados en la nube o repositorio físico

dependiendo la prioridad de los atributos, para que luego puedan ser utilizados y correlacionados.

Entre las variables a ser correlacionadas se tiene a los valores de conducta alimentaria con los porcentajes de aprobación y reprobación, que se obtienen en cada semestre.

2.3 Esquema para monitorear hábitos alimenticios utilizando un teléfono móvil

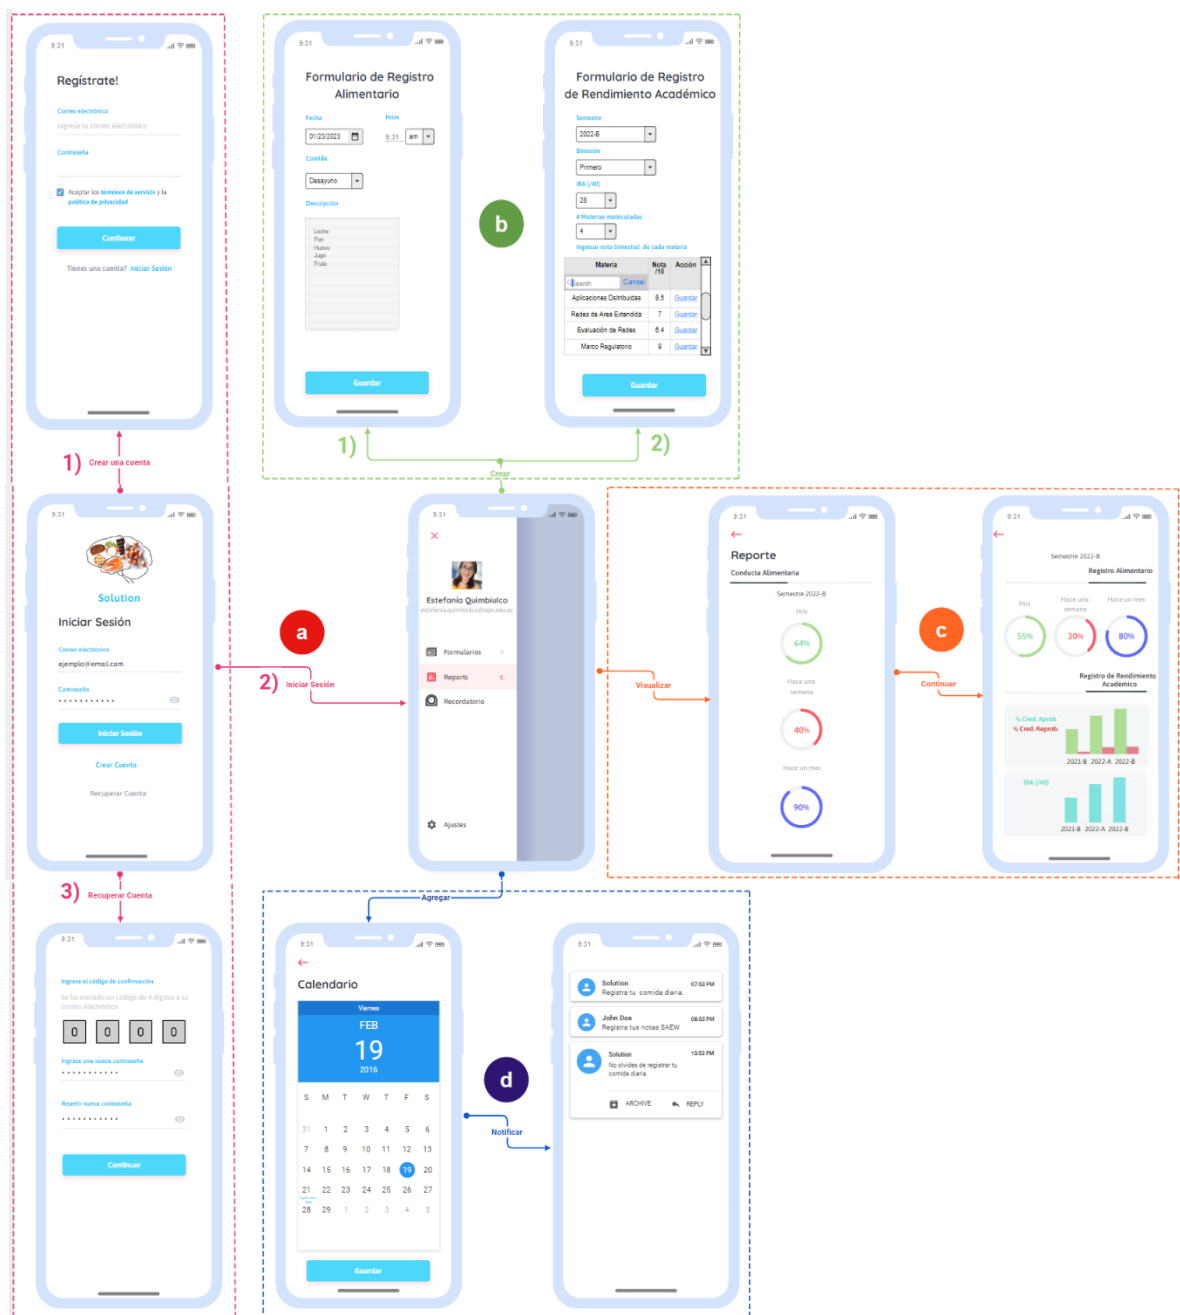


Figura 2. 20 Diseño de una aplicación móvil que permite el monitoreo de hábitos alimenticios

En la Figura 2.20, se implementa un esquema que puede ser utilizado a futuro para monitorear los hábitos alimenticios utilizando un teléfono móvil. El esquema se divide en 4 secciones **a), b), c) y d)**. A continuación, se describe la funcionalidad de cada sección.

En la **Sección a)** se tiene la pantalla de inicio de la aplicación (Figura 2.21). Esta aplicación se denomina Solución ya que su objetivo principal es brindar la información necesaria al usuario para que mejore sus hábitos alimenticios. En esta sección el usuario podrá **1. Crear una Nueva Cuenta, 2. Iniciar Sesión y 3. Recuperar Cuenta.**

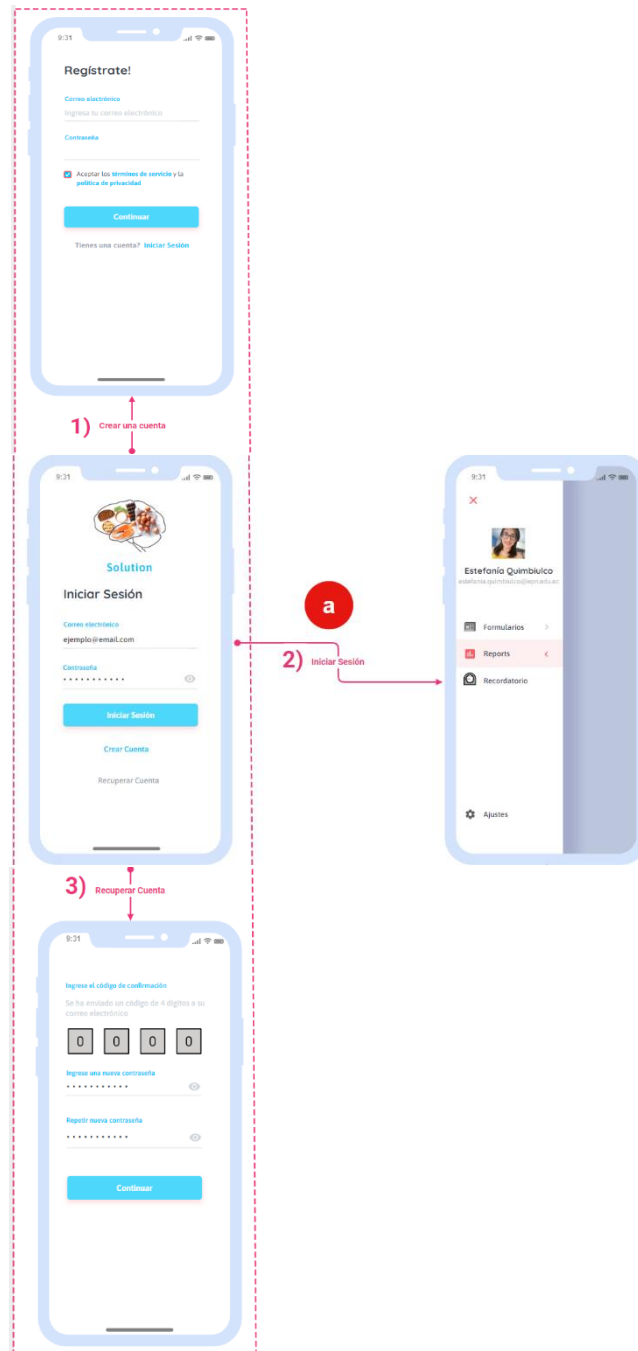


Figura 2. 21 Pantalla de Inicio

1. Para que el usuario pueda utilizar la aplicación es necesario que se registre. Para registrarse solo se necesita de un correo electrónico personal y una contraseña. Al ingresar los datos solicitados se debe aceptar los términos de servicio y la política de privacidad para no tener ningún inconveniente.
2. Si el usuario ya se encuentra registrado, solo tiene que iniciar sesión con sus credenciales personales.
3. En el caso de que el usuario no pueda iniciar sesión debido a que se le olvidó la contraseña. La aplicación le enviará un código de confirmación de 4 dígitos a su correo electrónico. Una vez validado el código, se ingresará una nueva contraseña.

En la **Sección b)** se tiene la opción de formularios (Figura 2.22). En esta opción se puede escoger entre el **1. Formulario de Registro Alimentario** o el **2. Formulario de Registro de Rendimiento Académico**.



Figura 2. 22 Creación de Formularios

1. El usuario debe registrar diariamente su conducta alimentaria; en esta parte se debe ingresar la fecha, hora, comida (desayuno, refacción matutina, almuerzo, refacción vespertina y cena) [46] y la descripción de la comida. Se recomienda hacer el registro después de cada comida para que no se pierda información.
2. El usuario debe registrar bimestralmente su rendimiento académico; en esta parte se debe ingresar el periodo del semestre, el bimestre en el que se encuentra, su IRA y el número de las materias que se encuentra tomando actualmente, en esta opción se desplegará una tabla nx3 donde se registra el nombre de la materia y la nota obtenida de esa materia. Se recomienda hacer uso de la plataforma SAEW, para ingresar los datos correctos.

La **Sección c)** se basa en la visualización de reportes (Figura 2.23), en la primera pestaña se muestran los porcentajes de la conducta alimentaria registrada por los sensores del teléfono móvil y en la siguiente pestaña se muestra los porcentajes obtenidos en el registro alimentario, y los porcentajes de aprobación, reprobación y IRA, calculados mediante registro de rendimiento académico.

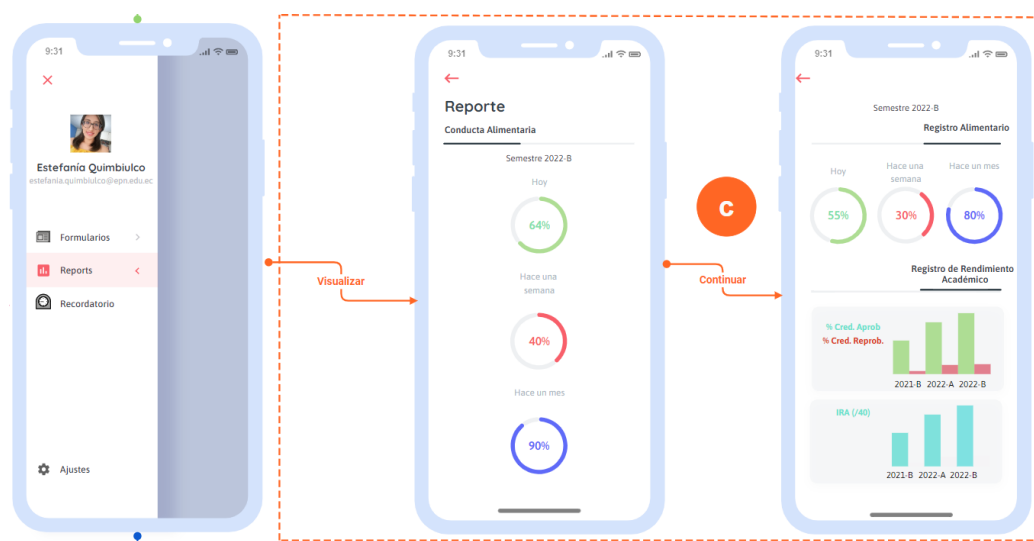


Figura 2. 23 Visualización de reportes

En la Figura 2.23 se visualiza primero el periodo del semestre en el cual se está monitoreando, luego se puede observar el porcentaje promedio de datos recolectados hace un mes, hace una semana y actualmente.

Al continuar se puede visualizar los porcentajes promedios del registro diario alimentario que el usuario ingresa en cada formulario. Así como también, el avance del (%) créditos aprobados, reprobados y IRA, que se registra semestralmente.

Finalmente, se tiene la **Sección d)** (Figura 2.24), en esta parte se puede agregar un recordatorio, para que el usuario no se olvide de hacer el registro diario de sus comidas y el registro bimestral de sus notas.

La funcionalidad del recordatorio es notificar al usuario, que realice el registro alimentario o rendimiento académico, a través de un mensaje enviado por la aplicación. Las notificaciones para el registro diario serán enviadas cada cierto tiempo todos los días, hasta que al menos se haya registrado las tres comidas diarias y para el registro del rendimiento académico se notificará cada cierto tiempo por un día.

En el caso de que el usuario quiera desactivar las notificaciones diarias, lo puede hacer mediante la opción ajustes. Sin embargo, no es aconsejable debido a que el registro alimentario diario es de mucha de importancia.

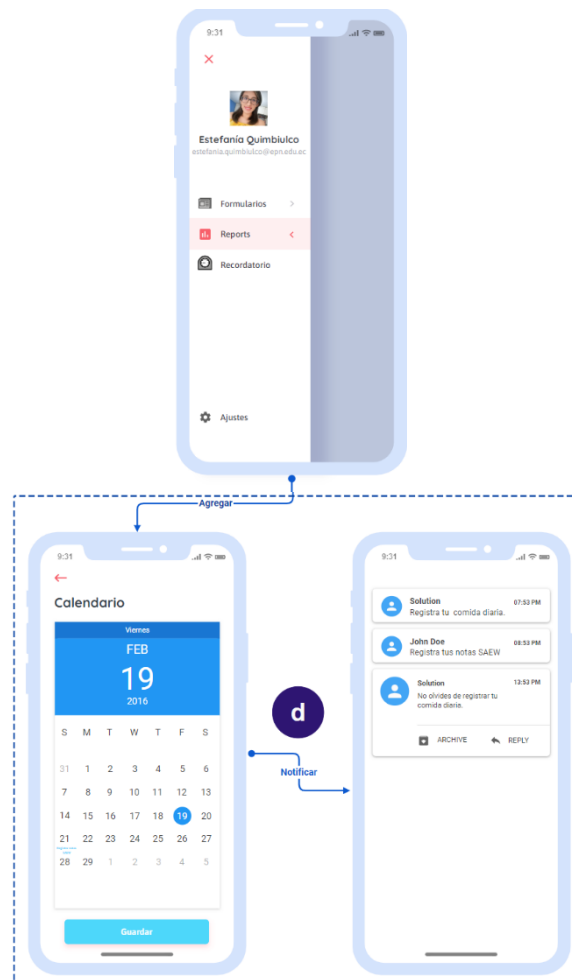


Figura 2. 24 Agregación de recordatorio

3. RESULTADOS, CONCLUSIONES Y RECOMENDACIONES

3.1 Resultados

En esta sección se presenta una discusión sobre los diferentes parámetros que se utilizan para la detección de hábitos alimenticios, revisados en la sección 2.1. Estos parámetros fueron clasificados según los sensores utilizados, la ubicación del sensor, el algoritmo de aprendizaje, el número de participantes que intervinieron en cada caso, el entorno en el que se desarrolló cada estudio y las métricas de evaluación (exactitud, precisión, recuperación y puntuación F1). Al finalizar la sección se propone un modelo futuro que permita el monitoreo de los hábitos alimenticios, basado en las comparaciones de los parámetros obtenidos en los diferentes casos de estudio.

3.1.1 Comparación de los casos de estudio

En los enfoques basados en sensores IMU detallados en la Tabla 3.1, la métrica de evaluación que se utiliza para la comparación es la puntuación F1.

Tabla 3. 1 Agrupación de los parámetros más relevantes de los enfoques basados en sensores IMU

Estudio	Algoritmo	Ubicación	# Personas	F1
[25]	muñeca	DNN	36	92%
[26]	muñeca	RF	8	61%
[27]	muñeca	CNN Y LSTM	10	80%
[28]	muñeca	CNN Y LSTM	12	91%
[29]	muñeca	HMM	10	76%
[31]	Músculo temporal	WVSM	4	91 %
[32]	muñeca	RF	7	76%
[33]	Ojos	RF	38	67%
[36]	Cabeza	DT, NN, MLP, SVM Y WSVM	4	87%

En el caso de estudio 1 [25], caso de estudio 2 [26], caso de estudio 5 [29] y caso de estudio 8 [32], se aplican diferentes algoritmos pero la ubicación del sensor en estos casos es la misma; por lo que se puede observar mediante la comparación de resultados, que el algoritmo DNN es el que tiene mayor porcentaje F1 debido a que su algoritmo se lo entreno con un mayor número de participantes.

Por otro lado, en los casos de estudio 3 [27], y 4 [28] se observa la aplicación de los mismos algoritmos CNN y LSTM, la ubicación del sensor en ambos en la misma, pero el valor F1 es mayor en el caso de estudio 4 debido a que tiene mayor número de muestras.

Sin embargo, en el caso de estudio 7 [31], el caso de estudio 9 [33] y el caso de estudio 12 [36] no cumplen con lo dicho anteriormente, debido a que la ubicación de los sensores son diferentes, por lo que se puede decir que ubicar un sensor IMU en los anteojos no es recomendable ya que el algoritmo no es muy preciso y confunde las acciones de comer con otras actividades.

A continuación, se compara los enfoques basados en sensores de micrófono detallados en la Tabla 3.2, para este caso la métrica de evaluación que se utiliza para el análisis es la exactitud, ya que todos los casos de estudio comprenden de este valor.

Tabla 3. 2 Agrupación de los parámetros más relevantes de los enfoques basados en sensores de micrófono

Estudio	Ubicación	Algoritmo	# Personas	Ambiente	Exactitud
[37]	oreja	SVM	28	laboratorio	94%-95%
		RBM		libre	65%-76%
[38]	oreja	CNN	14	libre	77%-94%
[39]	cuello dif. alimento líquido sólido	DT	12	Laboratorio	87%
					100%
					100%
[40]	cabeza	SVM	9	libre	97%

Se puede decir que el mejor algoritmo aplicable cuando se utiliza sensores de micrófono es DT, porque tiene valores altos en la exactitud. Sin embargo, este caso de estudio se llevó a cabo solo en entornos de laboratorio.

Si se comparan los casos de estudio donde sus metodologías se probaron en un entorno libre, como son los casos de estudio 16 [40], 13 [37] y 14 [38], se observa que SVM es el algoritmo con mayor porcentaje de exactitud.

Finalmente, se analiza los enfoques basados en sensores piezoeléctricos detallados en la Tabla 3.3, la métrica de evaluación que se utiliza para este análisis sobre la detección de alimentación es la puntuación F1.

Tabla 3. 3 Agrupación de los parámetros más relevantes de los enfoques basados en sensores piezoeléctricos

Estudio	Ubicación	Algoritmo	# Personas	Precisión	F1
[41]	oreja	ANN	30	-	91%
[42]	cuello	RF	10	94%	
[43]	músculo temporal ojos	SVM	10	-	99.85%
[44]	oreja muñeca cuello	LDA	12	97%	93%

En el caso de estudio 17 [41], se puede evidenciar que el algoritmo con mayor F1 es el SVM en comparación con el caso de estudio 19 [43] y el caso de estudio 20 [44]. Este valor indica que la metodología se puede utilizar en un entorno libre sin restricciones, sin embargo, requiere de un sensor adicional que esté conectado en el músculo temporal mediante el uso de anteojos.

Por esta razón en los casos de estudio 19 [43] y 20 [44], recomiendan el uso de varios sensores pero aclaran que la colocación de estos en diferentes partes del cuerpo causan molestias al usuario.

3.1.2 Porcentajes de utilización de Sensores, Ubicación del Sensor y el Algoritmo de Aprendizaje

Para definir los parámetros que sean útiles en una aplicación futura es necesario la comparación de otros factores. En esta sección se habla de la comparación de los porcentajes de utilización de Sensores, Ubicación del Sensor y el Algoritmo de Aprendizaje.

En la Figura 3.1, se detallan los porcentajes de utilización de los sensores, como se puede evidenciar existe mayor demanda en la utilización de sensores IMU (acelerómetro, inercial, giroscopio) con un 60%. Sin embargo, los estudios basados en sensores de micrófono y

piezoeléctricos poseen limitados estudios, esto debido a que la mayoría de las investigaciones, ya sea de enfoques basados en micrófono o piezoeléctricos, hacen uso de un sensor IMU adicional con el fin de obtener mejores resultados.

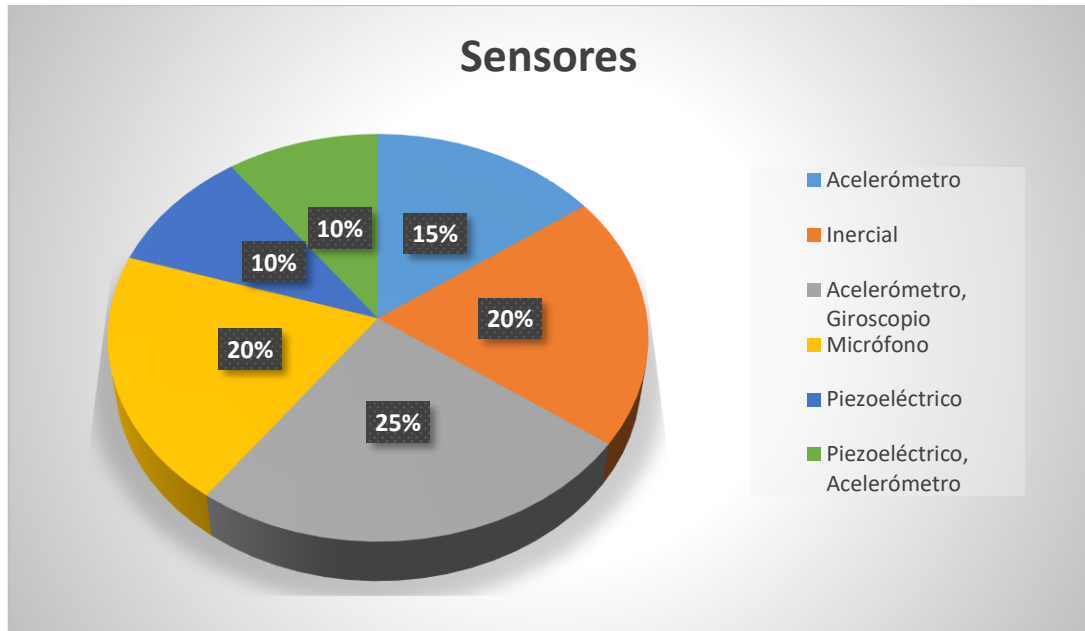


Figura 3. 1 Porcentajes de utilización de los sensores

En la Figura 3.2, se muestran los porcentajes de utilización de la ubicación de los sensores. Como se puede constatar un sensor colocado en la muñeca y un sensor ubicado en la mano sobrepasan el 50% de utilización. Este resultado se debe a que la colocación del sensor en ubicaciones como: músculo temporal, mandíbula, ojos, cabeza, oreja y cuello; no son adaptables al usuario en el mundo real, ya que su implementación conlleva a montar un sensor en accesorios adicionales, por ejemplo: sombrero/gorras, anteojos, collares, anillos, etc.

Gracias a esta comparación se puede sugerir no solo implementar un esquema para teléfonos inteligentes sino también en relojes inteligentes que sean capaces de monitorear hábitos alimenticios.

Por otro lado, en la Figura 3.3, se muestran los porcentajes de los algoritmos de clasificación más utilizados, donde se puede evidenciar que el algoritmo RF tiene un porcentaje de utilización alto, seguido del algoritmo SVM y CNN. Estos tres algoritmos comprenden un 53% de utilización.

Por otro lado, es necesario evidenciar que el 29% de los algoritmos han sido utilizados por una sola ocasión y el 18% en dos ocasiones. Entonces se puede decir que estos algoritmos no son ampliamente utilizados en el monitoreo automático de hábitos alimenticios.

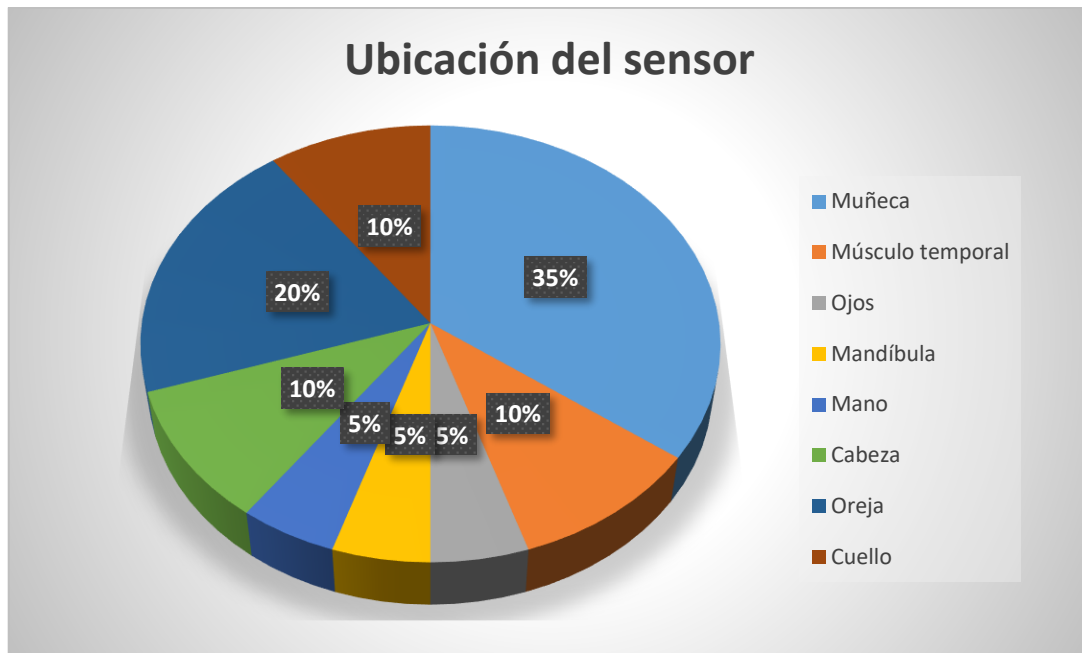


Figura 3. 2 Porcentajes de ubicación de los sensores




Figura 3. 3 Porcentaje de utilización del algoritmo de aprendizaje

3.1.3 Parámetros para la implementación de un futuro modelo

Con la comparación desarrollada en las secciones 3.1.1. y 3.1.2., se puede establecer los siguientes parámetros: ubicación del sensor, selección de sensor, y el algoritmo de

aprendizaje, sugeridos para futuras investigaciones. Así como también, se explica la correlación de las variables.

- **Ubicación del sensor:** los sensores se pueden ubicar en diferentes partes del cuerpo; sin embargo, se debe tomar en cuenta la comodidad del usuario que lo va a ocupar. Es por esta razón que las ubicaciones del sensor que se recomienda utilizar es la muñeca y la mano. Estas ubicaciones permiten implementar aplicaciones que puedan ser utilizadas en teléfonos y en relojes inteligentes.
- **Selección del sensor:** los sensores IMU permiten la detección de la actividad alimentaria mediante los movimientos de la muñeca y de la mano. Además, son sensores de bajo costo por lo que son ampliamente utilizados.
- **Algoritmo de aprendizaje:** los resultados de los algoritmos predictores dependen mucho del tamaño de la base de datos, ya que estos se utilizan para entrenar el algoritmo. Durante la comparación de los casos de estudio se obtuvo que SVM, RF y CNN, son algoritmos con mayor utilización y comprenden de porcentajes altos en las métricas de evaluación.

Sin embargo, hay que considerar que en el caso del algoritmo SVM, mientras mayor sea el conjunto de datos, mayor será el tiempo de entrenamiento. Por otro lado, con el algoritmo RF, se obtiene mejores resultados de predicción que otros algoritmos, pero tiende a sobreajustarse. Finalmente, el algoritmo CNN es muy útil debido a su alta potencia de cálculo, pero la mayor parte necesita de más datos de entrenamiento para construir el modelo.

Para el procesamiento y entrenamiento de datos se pueden utilizar herramientas de software como: Weka [47] y Rapid Miner [48] que son de libre uso y contienen interfaces gráficas fáciles de utilizar.

Con los parámetros descritos anteriormente se puede desarrollar alternativas que puedan ser utilizadas a futuro, para monitorear los hábitos alimenticios de estudiantes universitarios, utilizando teléfonos y relojes inteligentes.

El proceso de las alternativas se basaría en la recolección de datos mediante los sensores IMU que captan la conducta alimentaria a través de los movimientos de la muñeca. Esta información se agrupa en una base de datos, para luego ser procesada. En la parte de análisis de datos se aplicaría el algoritmo de aprendizaje (RF, SVM, CNN) que mejor convenga para esa base de datos. Por último, se valida la conducta alimentaria. Al definir la conducta alimentaria se da paso a una correlación con los porcentajes de aprobación y

reprobación bimestrales que permiten medir el rendimiento académico de un estudiante, los cuales son registrados en los formularios de la aplicación.

3.2 Conclusiones

En el presente trabajo de integración curricular se pudo obtener las siguientes conclusiones:

- El objetivo de este proyecto es analizar las alternativas que permitan mejorar el rendimiento académico de los estudiantes universitarios, mediante aplicaciones IoT. Para ello, fue necesario recopilar información a través de diferentes fuentes bibliográficas que permitan dar un enfoque apropiado al tema. En relación con esto, se puede concluir que los principales factores que influyen en la alimentación de los estudiantes universitarios son la modificación del entorno social, los horarios de clases, la condición económica y familiar.
- Al analizar los diferentes estudios basados en sistemas automáticos de monitoreo de los hábitos alimenticios publicados en los últimos 5 años, utilizando sensores portátiles, se puede concluir que no existe un monitoreo automático preciso y objetivo, que cumpla con todas las funcionalidades como: masticación, deglución y la detección del tipo de alimento, aplicado a un mismo prototipo.
- El tipo de trabajo implementado es de casos de estudio basados en diferentes enfoques, por este motivo el uso de tablas con variables y valores de importancia de las diferentes publicaciones fueron indispensables para la extracción de los parámetros en el análisis de resultados.
- Se puede concluir que los sensores IMU son los más utilizados en investigaciones de monitoreo de la ingesta de alimentos con aplicaciones IoT, ya que permiten captar los movimientos en varias direcciones, siendo ideales en dispositivos para la mano.
- La ubicación del sensor con mayor porcentaje de utilización fue la muñeca, se puede concluir que este valor resultó alentador al considerar su uso en un prototipo real debido a la comodidad que brinda al usuario en comparación a los otros porcentajes de utilización de las ubicaciones de los sensores, por ejemplo: la mandíbula, cuello o cabeza.
- Los resultados proporcionados de las métricas de evaluación de cada estudio permitieron realizar una comparación entre los algoritmos de aprendizaje bajo

diferentes condiciones. Se concluye que fueron tres algoritmos con más porcentaje de utilización, los cuales son: el algoritmo SVM, el algoritmo RF y el algoritmo CNN.

- Mediante la comparación de los parámetros de cada caso de estudio, se concluye que una alternativa que permite monitorear los hábitos alimenticios consiste en la utilización de sensores IMU conectados a un teléfono o reloj inteligente para la recolección de datos y el uso de los algoritmos SVM, RF y CNN para el análisis de datos.

3.3 Recomendaciones

- Los casos de estudio contienen una gran cantidad de información, por lo que se recomienda realizar una tabla de resumen con las variables y los valores que sean de gran importancia para el análisis de resultados.
- Se recomienda agrupar los casos de estudios según los tipos de sensores que se utiliza, con el fin de obtener una clasificación que permita el análisis y la depuración de información de manera eficaz.
- Mediante el análisis de los casos de estudio se pudo observar que mientras más sensores se utilicen en la detección de conducta alimentaria mejor serán sus métricas de evaluación; sin embargo, no es recomendable este tipo de práctica debido a que implementar un prototipo con varios sensores puede llegar hacer incómodo para el usuario en la vida real.
- Al proponer un modelo de monitoreo de hábitos alimenticios, se recomienda que la información englobe el tipo de sensor, la ubicación del sensor, el algoritmo de aprendizaje que se aplica y los valores de las métricas de evaluación que se obtienen, permitiendo que los estudios sean de mayor utilidad en futuras investigaciones.

4. REFERENCIAS BIBLIOGRÁFICAS

- [1] D.-L. Yang, F. Liu, and Y.-D. Liang, "A Survey of the Internet of Things," Proc. 1st Int. Conf. E-bus. Intell., pp. 358–366, 2010, [Online]. Available: <http://dx.doi.org/10.1016/j.comnet.2010.05.010> (accessed Nov 2, 2022).
- [2] L. Fedele, "From Basic Maintenance to Advanced Maintenance," Methodol. Tech. Adv. Maint., pp. 63–112, 2011, doi: 10.1007/978-0-85729-103-5_5 (accessed Nov 2, 2022).
- [3] Y. E. Pinos Quichimbo, P. I. Urgilez Angulo, K. G. Saquina Solorzano, K. S. Oñate Villaruel, and M. A. Guillen Godoy, "Malos hábitos alimenticios y cansancio mental en los estudiantes universitarios del Ecuador (caso cantón Milagro)," Anatomía Digit., vol. 2, no. 4, pp. 60–70, 2020, doi: 10.33262/anatomiadigital.v2i4.1179 (accessed Nov 2, 2022).
- [4] J. Salazar and S. Silvestre, "Internet de las cosas (IoT)," TechPedia, p. 34, 2017, [Online]. Available: <https://core.ac.uk/download/pdf/81581111.pdf> (accessed Nov 2, 2022).
- [5] D. A. R. M. Erika and D. R. Hernández, "Diseño de un método para identificar necesidades y oportunidades para la implementación de Internet de las cosas (IoT) aplicable a oficinas de trabajo donde permanezcan entre 30 y 70 personas y planteamiento de un caso práctico de solución en las oficinas," Univ. Dist., p. 157, 2016, [Online]. Available: <http://repository.udistrital.edu.co/bitstream/11349/5343/1/RamirezMadridDavidAndres2017.pdf> (accessed Nov 2, 2022).
- [6] O. Ivermesan, P. Friess, P. Guillemin, S. Gusmeroli, H. Sundmaeker, and P. Bassi, A., Doody, "Internet of Things „ Γιαγικστο Σων Πραγμασων " Δ Ττηρηδ Ιδ Τγδια Μδ Δμφα Η Σην Κασ " Οικον Παρακολοτηη Η Α Θδνων Internet of Things „ Γιαγικστο Σων Πραγμασων " Δ Ττηρηδ Ιδ Τγδια Μδ Δμφα Η Σην Κασ " Οικον Παρακολοτηη Η Α Θδνων," Cyber Resil. Syst. Networks, vol. 14, no. July 2016, pp. 1–150, 2009, [Online]. Available: http://link.springer.com/10.1007/978-3-319-77492-3_16 (accessed Nov 2, 2022).
- [7] T. Véliz, "Vida Saludable: Hábitos Y Prevención De Enfermedades.," Rev. Psicol. Gen. y Apl. Rev. la Fed. Española Asoc. Psicol., pp. 1–287, 2017, [Online]. Available: https://www.researchgate.net/publication/28200440_Dimensiones_del_estilo_de_vida_relacionado_con_la_salud_en_la_adolescencia_Una_revision (accessed Nov 2, 2022).

- 2022).
- [8] R. Loza, “Estudio de hábitos alimenticios y factores que los influncian en estudiantes que se encuentran cursando, 2do a 8vo nivel de la carrera de nutrición humana de la Pontificia Universidad Católica del Ecuador,” pp. 1–100, 2014 (accessed Nov 3, 2022).
 - [9] Emerson Roberto Yépez Herrera, Factores personales y sociales en el rendimiento académico universitario. 2017. [Online]. Available: [http://repositorio.espe.edu.ec/xmlui/bitstream/handle/21000/23222/Factores personales y sociales en el rendimiento académico universitario.pdf?sequence=1&isAllowed=y](http://repositorio.espe.edu.ec/xmlui/bitstream/handle/21000/23222/Factores%20personales%20y%20sociales%20en%20el%20rendimiento%20academico%20universitario.pdf?sequence=1&isAllowed=y) (accessed Nov 4, 2022).
 - [10] BETELGEUX, “Tecnologías de conservación de alimentos: Altas Presiones,” Betelgeux, pp. 1–16, 2018, [Online]. Available: <https://www.betelgeux.es/blog/2018/03/20/tecnologias-de-conservacion-de-alimentos-altas-presiones/> (accessed Nov 5, 2022).
 - [11] GDA EL COMERCIO, “Aplicaciones para móviles que ayudan a mejorar hábitos de alimentación,” 2021. <https://www.elcomercio.com/tendencias/aplicaciones-moviles-habitos-alimentacion-saludable.html> (accessed Nov 5, 2022).
 - [12] SAMSUNG, “¿Qué es Bixby Vision y cómo lo uso?,” 2022. <https://www.samsung.com/latin/support/mobile-devices/what-is-bixby-vision-and-how-do-i-use-it/> (accessed Nov 5, 2022).
 - [13] MyFitnessPal, “Una buena salud empieza por una buena alimentación.,” 2022, [Online]. Available: <https://www.myfitnesspal.com/es> (accessed Nov 8, 2022).
 - [14] Nootric, “Vida sana con nutricionistas de verdad,” 2022, [Online]. Available: <https://dkvclubdesalud.dkvseguros.com/nootric> (accessed Nov 8, 2022).
 - [15] myrealfood, “La app para mejorar tu estilo de vida” , [Online]. Available: <https://myrealfood.app/> (accessed Nov 9, 2022).
 - [16] SinAzucar.org, “Revelando el azúcar libre de los alimentos”, [Online]. Available: <https://www.sinazucar.org/> (accessed Nov 9, 2022).
 - [17] TabletZona, “Aqualert, una app muy curiosa pero ¿Útil?”, [Online]. Available: <https://tabletzona.es/aqualert-una-app-muy-curiosa-pero-util/> (accessed Nov 11, 2022).

- [18] G. M. Smith, “¿Qué es un Sensor y Qué Hace?,” 2020, [Online]. Available: <https://dewesoft.com/es/daq/que-es-un-sensor#:~:text=Un%20sensor%20es%20un%20dispositivo,para%20lectura%20o%20procesamiento%20adicional.> (accessed Nov 11, 2022).
- [19] Danfoss, “Libro blanco: Conectividad de sensores inteligentes del mañana,” 2021, [Online]. Available: <https://www.danfoss.com/es-es/about-danfoss/news/dcs/white-paper-smart-sensor-connectivity-of-tomorrow/> (accessed Nov 12, 2022).
- [20] V. M. Sebastian Raschka, *Aprendizaje automático con Python*, Segunda ed. Spain: MARCOMBO, S.A., 2019, [Online]. Available: <https://www.tagusbooks.com/leer?isbn=9788426727725&li=1&idsource=3001> (accessed Nov 15, 2022).
- [21] S. Rajbanshi, “Everything you need to know about Machine Learning,” 2021, [Online]. Available: <https://medium.com/machine-learning-community/everything-you-need-to-know-about-machine-learning-technology-f7e9b6ce07ce> (accessed Nov 17, 2022).
- [22] M. Usman and H. Chen, “Recent Trends in Food Intake Monitoring using Wearable Sensors,” pp. 1–27, 2021, [Online]. Available: <http://arxiv.org/abs/2101.01378> (accessed Nov 17, 2022).
- [23] O. Reynoso Orozco and T. E. Méndez-Luévano, “¿Es posible predecir el rendimiento académico? La regulación de la conducta como un indicador del rendimiento académico en estudiantes de educación superior,” *Diálogos sobre Educ. Temas actuales en Investig. Educ.*, vol. 9, no. 16, pp. 1–19, 2018 (accessed Nov 18, 2022).
- [24] “Reglamento del Régimen Académico de la Escuela Politécnica Nacional (Epn) (Codificación),” pp. 19, 2021, [Online]. Available: https://www.epn.edu.ec/wp-content/uploads/2022/07/codificacion_reglamento_de_regimen_academico_epn_reforma_mayo_2022_v.f.-signed.pdf (accessed Nov 21, 2022).
- [25] J. Lee, P. Paudyal, A. Banerjee, and S. K. S. Gupta, “A user-adaptive modeling for eating action identification from wristband time series,” *ACM Trans. Interact. Intell. Syst.*, vol. 9, no. 4, 2019, doi: 10.1145/3300149 (accessed Dic 1, 2022).
- [26] S. Zhang, R. Alharbi, M. Nicholson, and N. Alshurafa, “When generalized eating detection machine learning models fail in the field,” *UbiComp/ISWC 2017 - Adjunct*.

- Proc. 2017 ACM Int. Jt. Conf. Pervasive Ubiquitous Comput. Proc. 2017 ACM Int. Symp. Wearable Comput., no. June, pp. 613–622, 2017, doi: 10.1145/3123024.3124409 (accessed Dic 3, 2022).
- [27] K. Kyritsis, C. Diou, and A. Delopoulos, “End-to-end Learning for Measuring in-meal Eating Behavior from a Smartwatch,” Conf. Proc. ... Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. IEEE Eng. Med. Biol. Soc. Annu. Conf., vol. 2018, pp. 5511–5514, 2018, doi: 10.1109/EMBC.2018.8513627 (accessed Dic 4, 2022).
- [28] K. Kyritsis, C. Dlou, and A. Delopoulos, “Modeling Wrist Micromovements to Measure In-Meal Eating Behavior from Inertial Sensor Data,” IEEE J. Biomed. Heal. Informatics, vol. 23, no. 6, pp. 2325–2334, 2019, doi: 10.1109/JBHI.2019.2892011 (accessed Dic 4, 2022).
- [29] S. Stankoski, N. Reščič, G. Mežič, and M. Luštrek, “Real-time eating detection using a smartwatch,” Int. Conf. Embed. Wirel. Syst. Networks, pp. 247–252, 2020 (accessed Dic 5, 2022).
- [30] J. Kim, M. Lee, K. J. Lee, T. Y. Lee, B. C. Bae, and J. D. Cho, “An eating speed guide system using a wristband and tabletop unit,” UbiComp 2016 Adjun. - Proc. 2016 ACM Int. Jt. Conf. Pervasive Ubiquitous Comput., pp. 121–124, 2016, doi: 10.1145/2968219.2971460 (accessed Dic 7, 2022).
- [31] S. Wang, G. Zhou, L. Hu, Z. Chen, and Y. Chen, “CARE: Chewing activity recognition using non invasive single axis accelerometer,” UbiComp ISWC 2015 - Proc. 2015 ACM Int. Jt. Conf. Pervasive Ubiquitous Comput. Proc. 2015 ACM Int. Symp. Wearable Comput., pp. 109–112, 2015, doi: 10.1145/2800835.2800884 (accessed Dic 7, 2022).
- [32] E. Thomaz, I. Essa, and G. D. Abowd, “A practical approach for recognizing eating moments with wrist-mounted inertial sensing,” UbiComp 2015 - Proc. 2015 ACM Int. Jt. Conf. Pervasive Ubiquitous Comput., pp. 1029–1040, 2015, doi: 10.1145/2750858.2807545 (accessed Dic 8, 2022).
- [33] S. A. Rahman, C. Merck, Y. Huang, and S. Kleinberg, “Unintrusive eating recognition using Google Glass,” Proc. 2015 9th Int. Conf. Pervasive Comput. Technol. Heal. PervasiveHealth 2015, pp. 108–111, 2015, doi: 10.4108/icst.pervasivehealth.2015.259044 (accessed Dic 9, 2022).
- [34] Fan, Gong, and Lach, “Eating gestures detection by tracking finger motion,” in 2016 IEEE Wireless Health (WH), 2016, pp. 1–6. doi: 10.1109/WH.2016.7764549

(accessed Dic 12, 2022).

- [35] K. S. Chun, H. Jeong, R. Adaimi, and E. Thomaz, "Eating Episode Detection with Jawbone-Mounted Inertial Sensing," *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, vol. 2020-July, pp. 4361–4364, 2020, doi: 10.1109/EMBC44109.2020.9175949 (accessed Dic 13, 2022).
- [36] S. Wang et al., "Eating detection and chews counting through sensing mastication muscle contraction," *Smart Heal.*, vol. 9–10, pp. 179–191, 2018, doi: <https://doi.org/10.1016/j.smhl.2018.07.004> (accessed Dic 14, 2022).
- [37] Y. Gao et al., "iHear Food: Eating Detection Using Commodity Bluetooth Headsets," in *2016 IEEE First International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE)*, 2016, pp. 163–172. doi: 10.1109/CHASE.2016.14 (accessed Dic 16, 2022).
- [38] V. Papapanagiotou, C. Diou, and A. Delopoulos, "Chewing detection from an in-ear microphone using convolutional neural networks," *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, no. March 2018, pp. 1258–1261, 2017, doi: 10.1109/EMBC.2017.8037060 (accessed Dic 17, 2022).
- [39] Y. Bi, M. Lv, C. Song, W. Xu, N. Guan, and W. Yi, "AutoDietary: A Wearable Acoustic Sensor System for Food Intake Recognition in Daily Life," *IEEE Sens. J.*, vol. 16, no. 3, pp. 806–816, 2016, doi: 10.1109/JSEN.2015.2469095 (accessed Dic 18, 2022).
- [40] T. Kondo, H. Kamachi, S. Ishii, A. Yokokubo, and G. Lopez, "Robust Classification of Eating Sound Collected in Natural Meal Environment," in *Adjunct Proceedings of the 2019 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2019 ACM International Symposium on Wearable Computers*, 2019, pp. 105–108. doi: 10.1145/3341162.3343780 (accessed Dic 17, 2022).
- [41] M. Farooq and E. Sazonov, "Automatic measurement of chew count and chewing rate during food intake," *Electron.*, vol. 5, no. 4, 2016, doi: 10.3390/electronics5040062 (accessed Dic 21, 2022).
- [42] N. Alshurafa et al., "Recognition of nutrition intake using time-frequency decomposition in a wearable necklace using a piezoelectric sensor," *IEEE Sens. J.*, vol. 15, no. 7, pp. 3909–3916, 2015, doi: 10.1109/JSEN.2015.2402652 (accessed Dic 22, 2022).

- [43] M. Farooq and E. Sazonov, "A novel wearable device for food intake and physical activity recognition," *Sensors (Switzerland)*, vol. 16, no. 7, 2016, doi: 10.3390/s16071067 (accessed Dic 22, 2022).
- [44] M. Farooq and E. Sazonov, "Detection of chewing from piezoelectric film sensor signals using ensemble classifiers," in *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2016, pp. 4929–4932. doi: 10.1109/EMBC.2016.7591833 (accessed Dic 23, 2022)..
- [45] C. Hernández G. and J. Rodríguez R., "Preprocesamiento de datos estructurados," *Vínculos*, vol. 4, no. 2, pp. 27–48, 2008 (accessed Ene 25, 2022).
- [46] "5 comidas al día," 2018, [Online]. Available: <https://principal.url.edu.gt/noticias/5-comidas-al-dia/> (accessed Ene 25, 2022).
- [47] Arnold de Leon, "WEKA," *WekaIO*, 2023. <https://www.weka.io/> (accessed Ene 25, 2022).
- [48] I. M. Martin Schmitz, "RAPIDMINER," *Altair Company*, 2023. <https://rapidminer.com/platform/> (accessed Ene 25, 2022).

5. ANEXOS

ANEXO I.1 Cronograma de actividades semana 11

ANEXO I. 1 Cronograma de actividades semana 11

The screenshot shows a Trello board for 'Trabajo de integración curricular'. The board is organized into three columns: 'Pendiente', 'En proceso', and 'Finalizado'. Each column has a 'Agregar tarea' button at the top. The 'Pendiente' column contains one task assigned to 'Rosa' with a due date of 14/02. The 'En proceso' column contains one task assigned to 'Marrón' with a due date of 14/02. The 'Finalizado' column contains five completed tasks, all assigned to 'ESTEFANIA LOR...', each with a green checkmark icon.

Columna	Estado	Asignado a	Descripción de la Tarea	Fecha de Vencimiento	Completado
Pendiente	Pendiente	Rosa	Ajuste del documento final en base a las revisiones realizadas por el tutor	14/02	No
En proceso	En proceso	Marrón	Proponer un esquema que pueda ser implementado a futuro para monitorear los hábitos alimenticios utilizando un teléfono móvil	14/02	No
Finalizado	Finalizado	ESTEFANIA LOR...	Consultar las aplicaciones IoT en el consumo de alimentos	-	Si
Finalizado	Finalizado	ESTEFANIA LOR...	Estudiar las técnicas de aprendizaje de máquina utilizadas para la detección de hábitos alimenticios	-	Si
Finalizado	Finalizado	ESTEFANIA LOR...	Comparar los parámetros que se utilizan en diversos trabajos que detectan los hábitos alimenticios de una persona	-	Si
Finalizado	Finalizado	ESTEFANIA LOR...	Definir los parámetros que permiten medir el rendimiento académico de los estudiantes universitarios	-	Si
Finalizado	Finalizado	ESTEFANIA LOR...	Definir el tipo de aprendizaje de máquina recomendado para inferir los hábitos alimenticios en una persona	-	Si