

Computational Models for Nutritional Diagnosis and food recognition: A systematic review

Leonardo A. Bernal Saavedra ¹; Johannes Quiroz Guevara ²; Christian A. Dios Castillo ³

^{1,3}Universidad Tecnológica del Perú, Perú, U22244452@utp.edu.pe, U22236178@utp.edu.pe, C16763@utp.edu.pe

Abstract- *This study evaluates the effectiveness of computational models in improving nutritional diagnosis and food recognition through the analysis of image-based and numerical data. The research focuses on the performance of Deep Learning (DL), Machine Learning (ML), and hybrid DL + ML approaches, highlighting their role in nutritional evaluation, quality classification, and food identification. Results show that CNN – Based DL models achieve the highest accuracy when processing large and complex datasets, outperforming others architectures in tasks such as nutrient estimation, food quality assessment, and disease detection in crops and food products. Hybrid Ensemble – CNN models demonstrate superior robustness, offering more stable results and enhanced diagnostic performance across multiple applications.*

Keywords- *Deep Learning; Food Recognition; Nutritional Diagnosis; Machine Learning; Artificial Intelligence.*

Modelos Computacionales para el Diagnóstico Nutricional y Reconocimiento de Alimentos: Una Revisión Sistemática

Leonardo A. Bernal Saavedra ¹; Johannes Quiroz Guevara ²; Christian A. Dios Castillo ³

^{1,3}Universidad Tecnológica del Perú, Perú, U22244452@utp.edu.pe, U22236178@utp.edu.pe, C16763@utp.edu.pe

Resumen- Este estudio evalúa la efectividad de los modelos computacionales para mejorar el diagnóstico nutricional y el reconocimiento de alimentos, mediante el análisis de datos basados en imágenes y números. La investigación se centra en el rendimiento de enfoques de Deep Learning (DL), Machine Learning (ML) e híbridos DL + ML, destacando su papel en la evaluación nutricional, clasificación de calidad e identificación de alimentos. Los resultados muestran que los modelos DL basados en CNN alcanzan la mayor precisión al procesar conjuntos de datos grandes y complejos, superando a otras arquitecturas en tareas como la estimación de nutrientes, evaluación de calidad alimentaria y detección de enfermedades en cultivos y productos alimenticios. Los modelos híbridos ensemble-CNN demuestran una robustez superior, ofreciendo resultados más estables y un rendimiento de diagnóstico mejorado en múltiples aplicaciones.

Palabras Clave- Deep Learning; Reconocimiento de alimentos; Diagnóstico Nutricional; Machine Learning; Inteligencia Artificial

I. INTRODUCCIÓN:

La dieta diaria saludable y la ingesta equilibrada de nutrientes esenciales juegan un papel importante en el estilo de vida moderno. La estimación del contenido de nutrientes de una comida es un componente integral para poder mitigar enfermedades importantes, como la diabetes, la obesidad y las enfermedades cardiovasculares [1]. Sin embargo, como el control diario de la dieta por parte de expertos es prácticamente inviable, se aconseja a los pacientes que lleven un registro personal de sus costumbres alimenticias diarias, si bien estos métodos se emplean de manera extensa, su exactitud continúa siendo discutible, sobre todo en niños y adolescentes que no poseen la motivación y las habilidades necesarias [2]. Al margen de lo dicho, seguir una dieta balanceada es clave para prevenir y controlar varias enfermedades crónicas, según lo han evidenciado diversos estudios. Adoptar hábitos saludables, que incluya la práctica constante de actividad física, una alimentación equilibrada y un peso corporal apropiado puede hacer que la incidencia de estos problemas disminuya considerablemente. Además, mantener un seguimiento continuo de los alimentos ingeridos junto con la guía de expertos en salud ayuda a conseguir una nutrición más apropiada y sostenible.

El avance progresivo de la tecnología durante la última década ha impulsado el desarrollo de aplicaciones que permiten identificar alimentos y proporcionar su información nutricional, por medio del reconocimiento de imágenes, esto es el resultado de los progresos en las áreas de inteligencia artificial y visión por computadora, que permiten a los usuarios supervisar su salud todos los días mediante aplicaciones apropiadas [3]. Esta Revisión Sistemática de Literatura (RSL) tiene como objetivo identificar modelos computacionales de análisis de información para aumentar la eficacia sobre el diagnóstico nutricional y reconocimiento de alimentos, a través de la formulación de preguntas de investigación y el análisis de documentos científicos, siguiendo el desarrollo del modelo PRISMA. La investigación se justifica en la medida que los resultados permitirán determinar los modelos que se usarán para una posterior investigación orientada hacia la creación de aplicaciones inteligentes que permitan a los usuarios un análisis nutricional óptimo de los alimentos.

II. METODOLOGÍA

Este estudio se basa en una revisión sistemática de la literatura. Guiada por la formulación de preguntas específicas que facilitaron la identificación y selección de fuentes relevantes. Este método de formulación de preguntas no sólo permitió la identificación y selección sistemática de fuentes, sino que también facilitó una estructuración mucho más clara y lógica de todo el proceso de revisión. La pregunta principal que sirvió como punto de partida para la estructuración, identificación y selección de fuentes, así como el análisis e interpretación de los resultados es la siguiente: ¿Qué modelos computacionales de análisis de información existen para aumentar la eficacia sobre el diagnóstico nutricional y reconocimiento de alimentos?, de acuerdo con esta interrogante surgieron tres preguntas específicas, que se explican en la Tabla I. Estas preguntas específicas sirvieron como puntos de referencia adicionales que ayudaron a delimitar y profundizar en los principales hallazgos de la revisión.

TABLA I

ESTRUCTURA DE PREGUNTAS ESPECIFICAS

Pregunta	Palabras Clave	Propósito
¿Qué características tiene la eficacia sobre el diagnóstico nutricional y reconocimiento de alimentos?	Efficient, Performance, Diagnosis, Diagnostic, Analysis, Nutrition, Healthy, Intake.	Identificar y describir los factores que determinan la eficacia en el diagnóstico nutricional de los alimentos envasados, considerando parámetros de análisis, exactitud y relación con la salud y la ingesta nutricional.
¿Qué características tienen los modelos computacionales de análisis de información para aumentar la eficacia sobre el diagnóstico nutricional y reconocimiento de alimentos?	Food, Product, Packaged, Labeling, Value Table, Machine Learning, Deep Learning, neural networks	Analizar los modelos computacionales utilizados para procesar y evaluar información nutricional, identificando sus características técnicas (como uso de machine learning o deep learning) que contribuyen a mejorar la eficacia del diagnóstico nutricional.
¿Qué resultados se obtuvieron de la aplicación de los modelos computacionales de análisis de información en la eficacia sobre el diagnóstico nutricional y reconocimiento de alimentos?	Performance, Efficient, Diagnosis, Product, Packaged, Labeling, Machine Learning, Deep Learning	Evaluar los resultados y el impacto obtenido al aplicar modelos computacionales en el diagnóstico nutricional, determinando si mejoran la precisión, rapidez y confiabilidad del análisis de alimentos envasados.

La búsqueda de información se realizó en las bases de datos Web of Science (WOS) y SCOPUS. Para ello, se construyó una estrategia de búsqueda basada en los términos clave identificados a partir de las preguntas específicas de investigación, lo que permitió conformar la siguiente cadena de búsqueda en scopus: (TITLE-ABS-KEY (("efficient" OR "performance") AND ("diagnosis" OR "diagnostic" OR "analysis")) AND TITLE-ABS-KEY (("nutrition" OR "healthy" OR "intake") AND ("food" OR "product" OR "packaged" OR "labeling" OR "value table")) AND TITLE-ABS-KEY (("machine" OR "deep") AND "learning") OR "neural networks")) y la siguiente ecuación de búsqueda en wos: ("efficient" OR "performance") AND ("diagnosis" OR "diagnostic" OR "analysis") (Topic) and "nutrition" OR "healthy" OR "intake" (All Fields) and "food" OR "product" OR "packaged" OR "labeling" OR "value table" (All Fields) and (("machine" OR "deep") AND "learning") OR "neural networks" (All Fields). La estructura de dicha cadena se diseñó utilizando el conector AND para relacionar las distintas secciones vinculadas con las variables principales de análisis: la eficacia en el diagnóstico nutricional y reconocimiento de alimentos, los modelos computacionales aplicados (Machine Learning, Deep Learning, redes neuronales, entre otros) y los resultados esperados en términos de desempeño y precisión del análisis. Esta combinación garantizó la integración de los conceptos clave y una exploración exhaustiva del tema de estudio. Dentro de

cada sección, se aplicó el conector OR con el propósito de incluir sinónimos, variaciones terminológicas y conceptos relacionados, ampliando así el alcance de la búsqueda y asegurando la recuperación de estudios pertinentes.

TABLA II

FILTROS APLICADOS A LA CADENA DE BUSQUEDA

Item	Criterio	Nomenclatura	
		Scopus	Wos
1	Tiempo	PUBYEAR > 2022 AND PUBYEAR < 2026	2026 or 2025 or 2024 or 2023 (Publication Years)
2	Tipo de Documento	LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO (DOCTYPE , "cp") OR LIMIT-TO (DOCTYPE , "re")	Article or Data Paper or Review Article (Document Types)
3	Lenguaje	LIMIT-TO (LANGUAGE , "English")	English (Languages)
4	Acceso	(LIMIT-TO (OA , "all")	All Open Access

La TABLA II muestra los filtros, considerando criterios, que se utilizaron en la cadena de búsqueda para obtener un resultado más específico. Estos criterios se integraron a la cadena de búsqueda anterior, dando como resultado la siguiente cadena en Scopus: (TITLE-ABS-KEY (("efficient" OR "performance") AND ("diagnosis" OR "diagnostic" OR "analysis")) AND TITLE-ABS-KEY (("nutrition" OR "healthy" OR "intake") AND ("food" OR "product" OR "packaged" OR "labeling" OR "value table")) AND TITLE-ABS-KEY ((("machine" OR "deep") AND "learning") OR "neural networks")) AND PUBYEAR > 2022 AND PUBYEAR < 2027 AND (LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO (DOCTYPE , "cp") OR LIMIT-TO (DOCTYPE , "re")) AND (LIMIT-TO (LANGUAGE , "English")) AND (LIMIT-TO (OA , "all")). En WOS: ("efficient" OR "performance") AND ("diagnosis" OR "diagnostic" OR "analysis") (Topic) and "nutrition" OR "healthy" OR "intake" (All Fields) and "food" OR "product" OR "packaged" OR "labeling" OR "value table" (All Fields) and (("machine" OR "deep") AND "learning") OR "neural networks" (All Fields) and Open Access and 2026 or 2025 or 2024 or 2023 (Publication Years) and Article or Data Paper or Review Article (Document Types) and All Open Access (Open Access) and English (Languages) Con el objetivo de depurar las fuentes encontradas y elegir solo aquellas que son pertinentes para el análisis, se definieron criterios de inclusión y exclusión, los cuales se presentan en la TABLA III.

TABLA III

CRITERIOS DE INCLUSION Y EXCLUSION

Item	Criterios de Inclusión	Criterios de Exclusión
1	Estudios con análisis y comparación mediante IA.	Estudios sobre el impacto ambiental, económico o logístico

2	Estudios con métodos de diagnóstico nutricional.	Métodos diagnósticos del área médica
3	Modelos de diagnóstico nutricional y reconocimiento de alimentos.	Uso exclusivo de métodos estadísticos tradicionales
4	Aplicaciones prácticas o experimentales con datos reales.	Enfoques solo teóricos o revisiones bibliográficas

El modelo prisma utilizado fue de gran ayuda para el análisis de resultados, por tal motivo se empleó para el monitoreo sistemático de los estudios más relevantes. Los detalles se muestran en la Figura 1. Mediante dos bases de datos, este método hizo posible la identificación de 437 artículos: Scopus, que tiene 275 entradas, y Web of Science (WOS), con 162. Después, se suprimieron 95 registros duplicados, y quedaron 342 para el primer cribado. Se excluyeron 223 artículos después de evaluar títulos y resúmenes según los criterios establecidos en la TABLA III. Se evaluaron los otros en función de su disponibilidad, y se descartaron 6 porque no eran de acceso libre. Finalmente, se examinaron los 113 que quedaban en detallado, con la exclusión de 31 por no satisfacer los criterios concretos especificados en la TABLA III. Como consecuencia del estricto proceso de selección, que se ilustra en la Fig. 1, en la revisión sistemática se incorporaron 82 investigaciones, asegurando que solamente los artículos más pertinentes fueran tomados en cuenta.




Fig.1. Diagrama de Prisma

III. RESULTADOS Y DISCUSIONES

Bibliometría

Para la bibliometría de esta RSL, se utilizó el software VOSviewer, en el cual se cargó un archivo CSV con

todos los documentos y sus metadatos, lo que permitió obtener un resumen estadístico y un mapa de redes de investigación. En la Fig.2 se hizo un análisis sobre los campos temáticos de este RSL y se desarrolló un gráfico de barras para poder mostrar de forma entendible los datos, este análisis mostró que medicina concentra 101 documentos (18%) seguido por Ciencias Agrícolas y Biológicas con 82 (15%), luego sigue Informática con 71 (13%), después tenemos los campos de Ingeniería y Bioquímica, Genética y Biología molecular, abarcando 55 (10%) y 51 (9%) cada uno, posteriormente destacan los campos de proporción media, Enfermería con 27 (5%), Multidisciplinario con 21 (4%), Ciencia Medioambiental con 20 (4%), Ciencia de los Materiales con 16 (3%), Física y Astronomía con 16 (3%), Veterinario con 15 (3%). Química y Neurociencia tienen 14 (2%), Ingeniería Química e Inmunología y Microbiología cuentan con 12 (2%). Finalmente sigue Ciencias de la Decisión con 8, Profesiones de la salud con 7, Matemáticas con 6, Ciencias Sociales con 6, Ciencias de la Tierra y Planetarias con 5, Farmacología, Toxicología y Farmacéutica con 4, cada uno con el 1% del total.




Fig.2. Gráfico de Documentos según Campo Temático

Se desarrolló el análisis de Ocurrencia de los Keywords a través de un cuadro, esto se hace para comprobar que los documentos seleccionados tengan relación con el tema de estudio, además para saber la relevancia y los keywords más usados en los documentos, con el fin de poder agregarlos en la búsqueda del RSL, para que nuestro documento tenga mejor visibilidad y sea más fácil de encontrar. En la tabla se muestra un top 10 de los Keywords más concurrentes y con mayor fuerza de alcance.

TABLA IV
KEYWORDS CONCURRENTES

Nº	Keyword	Ocurrencias	Fuerza total de enlace
1	human	132	695
2	article	134	686
3	female	102	619
4	male	89	572
5	machine learning	146	553
6	controlled study	87	510
7	humans	90	492
8	adult	74	489
9	major clinical study	53	370
10	deep learning	85	224

Para un análisis más detallado de los artículos se implementó un procedimiento sistemático de análisis descriptivo en una matriz categórica multivariable alineada con enfoques metodológicos utilizados en Machine Learning y Computer Vision. Cada artículo fue clasificado mediante criterios de opción múltiple en función de su área de aplicación, tipo de modelo computacional, resultados obtenidos y tipo de datos empleados, lo que permitió capturar la naturaleza multidimensional de las investigaciones. A partir de eso se calcularon frecuencias absolutas y relativas, donde los porcentajes de obtuvieron mediante la normalización de cada categoría respecto al total de documentos analizados garantizando así comparabilidad y consistencia en la interpretación. Este enfoque no solo permitió cuantificar la distribución de las principales tendencias investigativas, sino también establecer una base sólida para el análisis comparativo entre categorías, reforzando la validez y rigurosidad de la investigación.

Para responder la primera pregunta específica de investigación ¿Qué características tiene la eficacia sobre el diagnóstico nutricional y reconocimiento de alimentos?, se realizó un análisis sistemático de las variables y características más frecuentemente estudiadas en el campo del diagnóstico nutricional y reconocimiento de alimentos. Este análisis se basó en la identificación y categorización de los aspectos más relevantes que los investigadores han evaluado en sus estudios. La Tabla V presenta los resultados de este análisis, donde se identificaron las áreas temáticas más estudiadas en la literatura científica revisada. Los datos revelan que los estudios se concentran principalmente en tres categorías principales: Enfermedades, Alimentos Preparados y Cultivos/Agricultura, cada una representando más del 50% de los estudios analizados. La característica más frecuentemente estudiada corresponde a las Enfermedades (54.88%), lo que refleja la importancia del diagnóstico nutricional en la prevención y tratamiento de condiciones de

salud. Los Alimentos Preparados ocupan el segundo lugar (53.66%), indicando el interés en automatizar la evaluación nutricional de comidas procesadas. Los Cultivos/Agricultura se posicionan en tercer lugar (52.44%), evidenciando la necesidad de evaluar la calidad nutricional desde la producción primaria. Las disciplinas científicas de la Agricultura fomentan las buenas prácticas para el aseguramiento de la Calidad Alimentaria. De manera complementaria, los procesos de Reconocimiento de Alimentos permiten el aseguramiento de la calidad en los Alimentos. Al consolidar la garantía en la excelencia de estos, se genera una mejora en la nutrición de la población humana.

TABLA V
CARACTERÍSTICAS DE LA EFICACIA ESTUDIADA

Ítem	Características	Frecuencia	% del total
1	Cultivos/Agricultura	43	52.44%
2	Alimentos Preparados	44	53.66%
3	Enfermedades	45	54.88%

Para responder la segunda pregunta específica de investigación ¿Qué características tienen los modelos computacionales de análisis de información para aumentar la eficacia sobre el diagnóstico nutricional y reconocimiento de alimentos?, se realizó un análisis detallado de los modelos computacionales identificados en la literatura científica revisada. El análisis se centró en determinar qué tipos de arquitecturas de machine learning y deep learning son más utilizados en este campo, así como evaluar su rendimiento promedio reportado. La Tabla VI presenta los resultados de este análisis, donde se categorizaron los diferentes modelos computacionales encontrados en los 82 artículos que conforman la muestra final. Cada modelo se evaluó según tres criterios principales. El número de estudios que lo implementan, su porcentaje de representación en el total de publicaciones analizadas y el promedio de eficacia reportado en los estudios que lo implementan. La Tabla VI revela varios hallazgos importantes sobre el panorama actual de los modelos computacionales en reconocimiento nutricional. En primer lugar, se observa que las Redes Neuronales Convolucionales concentran la mayor atención de la comunidad científica. Este dato refleja la preferencia de los investigadores por esta arquitectura, lo que se justifica por su eficacia promedio del 94.31%, la más alta entre todos los modelos analizados. En segundo lugar, los Modelos Ensemble logran una eficacia promedio muy competitiva del 93.53%. Este resultado sugiere que las estrategias de combinación de modelos ofrecen ventajas significativas en términos de robustez y precisión. Un tercer hallazgo relevante es la tendencia hacia la adopción de arquitecturas más recientes como los Visión Transformers (42.68%) con una eficacia del 92.37%, demostrando el interés creciente de la comunidad en enfoques innovadores. No obstante, el valor de estas arquitecturas depende en gran medida del contexto en el que se aplican. Las CNN sobresalen en escenarios con

datasets de tamaño moderado, recursos computacionales limitados y tareas centradas en características locales, además de ofrecer ventajas en interpretabilidad y madurez tecnológica; sin embargo, pueden ser superadas por los Transformers en situaciones que requieren grandes volúmenes de datos o la modelación de relaciones globales complejas, mientras que los enfoques Ensemble contribuyen a mejorar el rendimiento al reducir sesgo y varianza. Aun así, persisten retos importantes para su implementación real, los cuales no son homogéneos ni afectan por igual a todas las tecnologías, sino que dependen de la arquitectura y del contexto de la aplicación.

TABLA VI

PANORAMA ACTUAL DE MODELOS COMPUTACIONALES

Ítem	Modelos	ID Referencia	% del total	Prom. Eficacia
1	CNN/Redes Convolucionales	[4], [5], [6], [7], [8], [9], [10], [11], [12], [13], [14], [15], [16], [17], [18], [19], [20], [21], [22], [23], [24], [25], [26], [27], [28], [29], [30], [31], [32], [33], [34], [35], [36], [37], [38], [39], [40], [41], [42], [43], [44], [45], [46], [47], [48], [49], [50], [51], [52], [53], [54], [55], [56], [57], [58], [59]	68.29 %	94.31%
2	Vision Transformers	[4], [5], [6], [9], [10], [11], [12], [13], [19], [24], [25], [29], [31], [32], [33], [36], [39], [41], [42], [43], [46], [49], [52], [54], [59], [60], [61], [62], [63], [64], [65], [66], [67], [68], [69]	42.68 %	92.37%
3	Arquitecturas Pre-entrenadas	[4], [9], [12], [13], [14], [17], [24], [28], [31], [34], [36], [39], [40], [41], [42], [45], [48], [49], [52], [54], [55], [56], [57], [58], [59], [61], [65], [66], [67], [70]	36.59 %	92.71%
4	Modelos Ensemble	[4], [9], [10], [12], [14], [17], [18], [19], [24], [28], [30], [32], [34], [41], [42], [43], [49], [53], [60], [61], [63], [65], [69], [71], [72], [73], [74]	32.93 %	93.53%
5	Otros	[75], [76], [77], [78], [79], [80], [81], [82], [83], [84], [85]	13.41 %	90.47%

Para responder la tercera pregunta específica de investigación ¿Qué resultados se obtuvieron de la aplicación de los modelos computacionales de análisis de información en la eficacia sobre el diagnóstico nutricional y reconocimiento de alimentos?, Cuando nos preguntamos qué logran realmente estos sistemas de reconocimiento nutricional, es fascinante ver la diversidad de objetivos que los investigadores han perseguido. Para entender mejor qué valor aportan estos modelos computacionales, no basta con saber qué técnicas utilizan, sino que necesitamos entender qué tipos de resultados concretos están logrando y para qué los están usando. La Tabla VII nos da una respuesta muy reveladora. Al analizar los 82 artículos, descubrimos que la clasificación de calidad de alimentos es el objetivo más perseguido, apareciendo en 57 estudios (69.51%). Este dato tiene mucho sentido cuando pensamos en las implicaciones

prácticas. Pero lo que realmente es notable es lo equilibrada que está la distribución de los otros objetivos. La evaluación nutricional aparece en 43 estudios (52.44%), el reconocimiento e identificación en 42 estudios (51.22%), y la detección de enfermedades en 40 estudios (48.78%). Esta comparación sugiere que los investigadores han adoptado un enfoque muy integral, entendiendo que el reconocimiento nutricional efectivo no puede limitarse a una sola funcionalidad. Es decir, cuando un sistema identifica que tiene una manzana frente a él no se conforma solo con decir "es una manzana" sino que también quiere saber si esa manzana está en buen estado, qué valor nutricional tiene y si presenta algún problema. Esta aproximación general es lo que hace que estos sistemas sean realmente útiles en la práctica.

TABLA VII

RESULTADOS DE SISTEMAS DE RECONOCIMIENTO NUTRICIONAL

Ítem	Resultados	# de artículos	% del total
1	Detección de Enfermedades	40	48.78%
2	Clasificación de Calidad	57	69.51%
3	Evaluación Nutricional	43	52.44%
4	Reconocimiento/Identificación	42	51.22%

Una vez que entendemos qué logran estos sistemas, hoy surge naturalmente la pregunta: ¿Con qué información trabajan? Porque después de todo, no es lo mismo desarrollar un sistema que analiza datos numéricos como nutricionales de un producto, que uno que procese imágenes de comida para identificar qué plato está frente a nosotros. Para responder esta interrogante, la tabla VIII nos presenta un panorama muy claro. Al examinar los 82 estudios, descubrimos que los datos numéricos predominan ampliamente apareciendo en 73 artículos (89.02%). Este dato no sorprende, porque cuando hablamos de nutrición, al final del día estamos hablando de números concretos, calorías, gramos de proteína y porcentaje de grasas. La naturaleza cuantitativa de la información nutricional hace que estos datos sean fundamentales. Pero lo que sí resulta particularmente interesante es que los datos de imagen ocupan un segundo lugar apareciendo en 66 estudios (80.49%). Esto refleja la revolución que ha experimentado la visión computacional, y como los investigadores han encontrado en las imágenes de alimentos una fuente de información extraordinariamente rica. Es natural identificar visualmente lo que estamos comiendo, y ahora las máquinas también pueden desarrollar esa capacidad. Los datos de texto aparecen en 12 estudios (14.63%), lo que indica un rol más especializado para procesar descripciones de ingrediente, información nutricional en texto plano, o reseñas de usuarios. Ahora, o que realmente llama la atención es la presencia de mínima de audio y el video. Solo un estudio (1.22%) utiliza audio, y apenas seis estudios (7.32%) incorporan video. Esto

sugiere que, por desafíos técnicos y preferencias prácticas, la mayoría priorizan fotografías estáticas y datos estructurados, buscando un equilibrio entre calidad de información y viabilidad técnica.

TABLA VIII

CAPACIDAD DE TECNICAS ACTUALES Y PREFERENCIAS PRACTICAS

Ítem	Tipo de archivos	Frecuencia	% Total
1	Texto	12	14.63%
2	Numérico	73	89.02%
3	Audio	1	1.22%
4	Imagen	66	80.49%
5	Video	6	7.32%

IV.CONCLUSIONES

En conclusión, los modelos de reconocimiento nutricional basados en inteligencia artificial y visión por computadora muestran una gran efectividad en la clasificación y diagnóstico de alimentos debido a su capacidad para manejar diferentes tipos de datos complejos. Los hallazgos evidencian que las Redes Neuronales Convolucionales (CNN), son el enfoque más adoptado y exitoso en los estudios existentes ya que cuentan con una arquitectura más adecuada para contextos con recursos computacionales moderados y datasets de escala media, destacando por su eficiencia en la identificación de características visuales locales y por contar con herramientas de interpretabilidad consolidadas, seguidas por los Modelos Ensemble que al combinar múltiples arquitecturas, incrementan la precisión y robustez del sistema a costa de una mayor complejidad operativa y los Vision Transformers los cuales han demostrado ser particularmente eficaces para diferentes aplicaciones del reconocimiento nutricional siendo superiores en tareas de mayor complejidad demandando volúmenes de datos y capacidad computacional elevados, lo que limitan su aplicabilidad en entornos restringidos, los resultados demuestran que el reconocimiento nutricional ha encontrado aplicabilidad en diversas áreas de la cadena alimenticia, siendo las enfermedades en alimentos, los alimentos preparados y los cultivos como la agricultura los contextos más estudiados, esta distribución equilibrada indica que estos sistemas han trascendido las barreras tradicionales desde la producción agrícola hasta el consumo directo. Además, teniendo en cuenta los tipos de resultados generados, la clasificación de la calidad de alimentos emerge como el objetivo más perseguido en la investigación seguido por la evaluación nutricional, el reconocimiento e identificación de alimentos y la detección de enfermedades, esta aproximación integral refleja que los investigadores han desarrollado sistemas que abordan múltiples objetivos simultáneamente, como también los tipos de datos que se han utilizado en esta investigación confirman que la información numérica e imágenes son las modalidades más efectivas. En

general, los modelos CNN-Ensemble híbridos tienden a ofrecer mayor precisión y robustez, combinado con la alta eficacia de las CNN individuales con la estabilidad de los métodos Ensemble, lo que los convierte en una opción preferible para aplicaciones de reconocimiento nutricional.

V. DISPONIBILIDAD DE INFORMACIÓN

Como una forma de demostrar la transparencia en el trabajo de investigación, se registró en el siguiente enlace, la hoja de trabajo respectiva: [10.5281/zenodo.18627080](https://doi.org/10.5281/zenodo.18627080).

REFERENCIAS

[1] F. S. Konstantakopoulos, E. I. Georga, and D. I. Fotiadis, "A Review of Image-Based Food Recognition and Volume Estimation Artificial Intelligence Systems," IEEE Rev. Biomed. Eng., vol. 17, pp. 136–152, 2024, doi: 10.1109/RBME.2023.3283149.

[2] M. B. E. Livingstone, P. J. Robson, and J. M. W. Wallace, "Issues in dietary intake assessment of children and adolescents," British Journal of Nutrition, vol. 92, no. S2, pp. S213–S222, Oct. 2004, doi: 10.1079/bjn20041169.

[3] F. Jiang et al., "Artificial intelligence in healthcare: Past, present and future," Dec. 01, 2017, BMJ Publishing Group. doi: 10.1136/svn-2017-000101.

[4] C. Subbarayudu and M. Kubendiran, "Segmentation-based lightweight multi-class classification model for crop disease detection, classification, and severity assessment using DCNN," PLoS One, vol. 20, no. 5 May, May 2025, doi: 10.1371/journal.pone.0322705.

[5] K. A. Nfor, T. P. Theodore Armand, K. P. Ismaylovna, M. Il Joo, and H. C. Kim, "An Explainable CNN and Vision Transformer-Based Approach for Real-Time Food Recognition," Nutrients , vol. 17, no. 2, Jan. 2025, doi: 10.3390/nu17020362.

[6] C. S. Chen, G. Y. Chen, D. Zhou, D. Jiang, D. Chen, and S. H. Chang, "Improving fine-grained food classification using deep residual learning and selective state space models," PLoS One, vol. 20, no. 5 May, May 2025, doi: 10.1371/journal.pone.0322695.

[7] L. Kopitar, L. Bedrač, L. J. Strath, J. Bian, and G. Stiglic, "Improving Personalized Meal Planning with Large Language Models: Identifying and Decomposing Compound Ingredients," Nutrients , vol. 17, no. 9, May 2025, doi: 10.3390/nu17091492.

[8] H. Tamut, R. Ghosh, K. Gosh, and M. A. S. Siddique, "Enhancing Disease Detection in the Aquaculture Sector Using Convolutional Neural Networks Analysis," Aquaculture Journal, vol. 5, no. 1, Mar. 2025, doi: 10.3390/aquacj5010006.

- [9] J. Sharma et al., "Deep learning based ensemble model for accurate tomato leaf disease classification by leveraging ResNet50 and MobileNetV2 architectures," *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-98015-x.
- [10] S. Y. Chen et al., "Automated peanut defect detection using hyperspectral imaging and deep learning: A real-time approach for smart agriculture," *Smart Agricultural Technology*, vol. 11, Aug. 2025, doi: 10.1016/j.atech.2025.100943.
- [11] G. N. V. Rajareddy, K. Mishra, S. K. Satti, G. S. Chhabra, K. S. Sahoo, and A. H. Gandomi, "A digital twin-enabled fog-edge-assisted IoAT framework for Oryza Sativa disease identification and classification," *Ecol. Inform.*, vol. 87, Jul. 2025, doi: 10.1016/j.ecoinf.2025.103063.
- [12] R. Bianco et al., "2D Prediction of the Nutritional Composition of Dishes from Food Images: Deep Learning Algorithm Selection and Data Curation Beyond the Nutrition5k Project," *Nutrients*, vol. 17, no. 13, Jul. 2025, doi: 10.3390/nu17132196.
- [13] R. Roopa, R. Lingam, S. K. Ravva, A. Suresh, P. Balaji, and J. Avanija, "A Generalized Deep Learning Approach for Cross-Crop Plant Disease Detection Using the Plant Village Dataset," *Journal of Machine and Computing*, vol. 5, no. 3, pp. 1592–1605, Jul. 2025, doi: 10.53759/7669/jmc202505126.
- [14] M. R. A. Rashid et al., "An Ensemble Learning Framework with Explainable AI for interpretable leaf disease detection," *Array*, vol. 26, Jul. 2025, doi: 10.1016/j.array.2025.100386.
- [15] Z. Tang and A. Hoover, "Video-based Intake Gesture Recognition Using Meal-length Context," *ACM Trans. Comput. Healthc.*, vol. 6, no. 2, Apr. 2025, doi: 10.1145/3709151.
- [16] G. A. Senthil, K. M. Monica, R. Prabha, L. Prinslin, and R. Elavarasi, "Quantum AI: A Cognitive Machine Learning Technique based on Nurturing Food Security Sustainability Predictive Analysis for Life Science - Bioengineering in Healthcare," in *BIO Web of Conferences*, EDP Sciences, Apr. 2025. doi: 10.1051/bioconf/202517202002.
- [17] D. A. S. Daranagama and W. Takeuchi, "Smartphone application for detecting and visualizing basal stem rot disease stages in oil palm," *Frontiers in Remote Sensing*, vol. 6, 2025, doi: 10.3389/frsen.2025.1553844.
- [18] E. Junquera, N. Rico, I. Díaz, S. González, and B. Remeseiro, "Nutricnv: multitask learning framework for digital dietary tracking trained on EFSA's pancake dataset," *Neural Comput. Appl.*, Oct. 2025, doi: 10.1007/s00521-025-11542-6.
- [19] M. Khubaib et al., "Data-Efficient Wheat Disease Detection using Shifted Window Transformer: Enhancing Accuracy, Sustainability, and Global Food Security," *IEEE Transactions on Consumer Electronics*, 2025, doi: 10.1109/TCE.2025.3582267.
- [20] L. C. Naciri, R. F. Cabini, M. Melis, R. Crnjar, D. U. Pizzagalli, and I. Tomassini Barbarossa, "Automatic detection of fungiform papillae on the human tongue via Convolutional Neural Networks and identification of the best performing model," *Comput. Struct. Biotechnol. J.*, vol. 27, pp. 1927–1934, Jan. 2025, doi: 10.1016/j.csbj.2025.05.014.
- [21] V. Zatsu et al., "Revolutionizing the food industry: The transformative power of artificial intelligence-a review," *Dec. 30, 2024, Elsevier Ltd.* doi: 10.1016/j.fochx.2024.101867.
- [22] M. A. Al-Shannaq, S. AL-Khateeb, A. A. R. K. Bsoul, and A. A. Saifan, "Identification of Plant Diseases in Jordan Using Convolutional Neural Networks," *Electronics (Switzerland)*, vol. 13, no. 24, Dec. 2024, doi: 10.3390/electronics13244942.
- [23] C. Cruz-Carrasco, J. Díaz-Álvarez, F. Chávez de la O, A. Sánchez-Venegas, and J. Villegas Cortez, "Detection of Aspergillus flavus in Figs by Means of Hyperspectral Images and Deep Learning Algorithms," *AgriEngineering*, vol. 6, no. 4, pp. 3969–3988, Dec. 2024, doi: 10.3390/agriengineering6040225.
- [24] H. N. Ngugi, A. A. Akinyelu, and A. E. Ezugwu, "Machine Learning and Deep Learning for Crop Disease Diagnosis: Performance Analysis and Review," *Dec. 01, 2024, Multidisciplinary Digital Publishing Institute (MDPI).* doi: 10.3390/agronomy14123001.
- [25] J. Wang et al., "Improving healthy food recommender systems through heterogeneous hypergraph learning," *Egyptian Informatics Journal*, vol. 28, Dec. 2024, doi: 10.1016/j.eij.2024.100570.
- [26] T. Wang et al., "Microbiome-based correction for random errors in nutrient profiles derived from self-reported dietary assessments," *Nature Communications*, vol. 15, no. 1, Dec. 2024, doi: 10.1038/s41467-024-53567-w.
- [27] S. U. M. Rao, K. Sreekala, P. S. Rao, N. Shirisha, G. Srinivas, and E. Sreedevi, "Plant disease classification using novel integration of deep learning CNN and graph convolutional networks," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 36, no. 3, pp.

1721–1730, Dec. 2024, doi: 10.11591/ijeecs.v36.i3.pp1721-1730.

- [28] M. F. Shahid, T. J. S. Khanzada, M. A. Aslam, S. Hussain, S. A. Baowidan, and R. B. Ashari, “An ensemble deep learning models approach using image analysis for cotton crop classification in AI-enabled smart agriculture,” *Plant Methods*, vol. 20, no. 1, Dec. 2024, doi: 10.1186/s13007-024-01228-w.
- [29] N. Helmawati and E. Utami, “Utilization of the Convolutional Neural Network Method for Detecting Banana Leaf Disease,” *Jurnal RESTI*, vol. 8, no. 6, pp. 799–805, Dec. 2024, doi: 10.29207/resti.v8i6.6140.
- [30] T. A. Adjuik, N. A. A. Boi-Dsane, and B. A. Kehinde, “Enhancing dietary analysis: Using machine learning for food caloric and health risk assessment,” *J. Food Sci.*, vol. 89, no. 11, pp. 8006–8021, Nov. 2024, doi: 10.1111/1750-3841.17421.
- [31] E. S. Sreetha, G. N. Sundar, and D. Narmadha, “Enhancing Food Image Classification with Particle Swarm Optimization on NutriFoodNet and Data Augmentation Parameters,” *International Journal of Computational and Experimental Science and Engineering*, vol. 10, no. 4, pp. 718–730, Oct. 2024, doi: 10.22399/ijcesen.493.
- [32] T. Thangamuthu, A. Kareem, V. Kumara, U. U. Naik, S. Poojary, and B. Raju, “A survey of detecting leaf diseases using machine learning and deep learning in various crops,” *IAES International Journal of Artificial Intelligence*, vol. 13, no. 3, pp. 2498–2505, Sep. 2024, doi: 10.11591/ijai.v13.i3.pp2498-2505.
- [33] D. A. N. Gookyi et al., “TinyML for smart agriculture: Comparative analysis of TinyML platforms and practical deployment for maize leaf disease identification,” *Smart Agricultural Technology*, vol. 8, Aug. 2024, doi: 10.1016/j.atech.2024.100490.
- [34] P. Elangovan, V. Dhurairajan, M. K. Nath, P. Yogarajah, and J. Condell, “A Novel Approach for Meat Quality Assessment Using an Ensemble of Compact Convolutional Neural Networks,” *Applied Sciences (Switzerland)*, vol. 14, no. 14, Jul. 2024, doi: 10.3390/app14145979.
- [35] P. Chotwanvirat, A. Prachansuwan, P. Sridonpai, and W. Kriengsinyos, “Automated Artificial Intelligence–Based Thai Food Dietary Assessment System: Development and Validation,” *Curr. Dev. Nutr.*, vol. 8, no. 5, May 2024, doi: 10.1016/j.cdnut.2024.102154.
- [36] N. U. Gilal et al., “Evaluating machine learning technologies for food computing from a data set perspective,” *Multimed. Tools Appl.*, vol. 83, no. 11, pp.

32041–32068, Mar. 2024, doi: 10.1007/s11042-023-16513-4.

- [37] K. S. Lee, “Multi-Spectral Food Classification and Caloric Estimation Using Predicted Images,” *Foods*, vol. 13, no. 4, Feb. 2024, doi: 10.3390/foods13040551.
- [38] P. Chotwanvirat, A. Prachansuwan, P. Sridonpai, and W. Kriengsinyos, “Advancements in Using AI for Dietary Assessment Based on Food Images: Scoping Review,” 2024, JMIR Publications Inc. doi: 10.2196/51432.
- [39] M. Tariq et al., “Corn leaf disease: insightful diagnosis using VGG16 empowered by explainable AI,” *Front. Plant Sci.*, vol. 15, 2024, doi: 10.3389/fpls.2024.1402835.
- [40] G. S. Hukkeri, B. C. Soundarya, H. L. Gururaj, and V. Ravi, “Classification of Various Plant Leaf Disease Using Pretrained Convolutional Neural Network On Imagenet,” *Open Agric. J.*, vol. 18, no. 1, May 2024, doi: 10.2174/0118743315305194240408034912.
- [41] S. H. Kumar R and P. K. M., “Deep Convolutional Neural Networks Fusion with Support Vector Machines and K-Nearest Neighbors for Precise Crop Leaf Disease Classification,” 2024. [Online]. Available: www.ijacsa.thesai.org
- [42] B. Sowmiya, K. Saminathan, and M. C. Devi, “An Ensemble of Transfer Learning based InceptionV3 and VGG16 Models for Paddy Leaf Disease Classification,” *ECTI Transactions on Computer and Information Technology*, vol. 18, no. 1, pp. 89–100, Jan. 2024, doi: 10.37936/ecti-cit.2024181.254501.
- [43] G. Sheng et al., “A Lightweight Hybrid Model with Location-Preserving ViT for Efficient Food Recognition,” *Nutrients*, vol. 16, no. 2, Jan. 2024, doi: 10.3390/nu16020200.
- [44] P. Di Bitonto et al., “From data to nutrition: the impact of computing infrastructure and artificial intelligence,” *Exploration of Foods and Foodomics*, vol. 2, no. 6, pp. 810–829, 2024, doi: 10.37349/eff.2024.00063.
- [45] D. R. F. R. Anandhi and S. Sathiamoorthy, “Enhanced Sea Horse Optimization with Deep Learning-based Multimodal Fusion Technique for Rice Plant Disease Segmentation and Classification,” *Engineering, Technology and Applied Science Research*, vol. 13, no. 5, pp. 11959–11964, Oct. 2023, doi: 10.48084/etasr.6324.
- [46] J. Akther, A. A. Nayan, and M. Harun-Or-roshid, “Potato Leaves Blight Disease Recognition and Categorization Using Deep Learning,” *Engineering Journal*, vol. 27, no. 9, pp. 27–38, Sep. 2023, doi: 10.4186/ej.2023.27.9.27.

- [47] H. H. Alshammari and H. Alkhiri, "Optimized recurrent neural network mechanism for olive leaf disease diagnosis based on wavelet transform," *Alexandria Engineering Journal*, vol. 78, pp. 149–161, Sep. 2023, doi: 10.1016/j.aej.2023.07.037.
- [48] C. Vengaiah and S. R. Konda, "A Review on Tomato Leaf Disease Detection using Deep Learning Approaches," Aug. 01, 2023, Auricle Global Society of Education and Research. doi: 10.17762/ijritcc.v11i9s.7479.
- [49] S. N. Mohanty, H. Ghosh, I. S. Rahat, and C. V. R. Reddy, "Advanced Deep Learning Models for Corn Leaf Disease Classification: A Field Study in Bangladesh †," *Engineering Proceedings*, vol. 59, no. 1, 2023, doi: 10.3390/engproc2023059069.
- [50] P. Goyal, D. K. Verma, and S. Kumar, "DIAGNOSIS OF PLANT LEAF DISEASES USING IMAGE BASED DETECTION AND PREDICTION USING MACHINE LEARNING APPROACH," *Econ. Comput. Econ. Cybern. Stud. Res.*, vol. 57, no. 4, pp. 293–312, 2023, doi: 10.24818/18423264/57.4.23.18.
- [51] S. Gan, D. Zhou, Y. Cui, and J. Lv, "A Neural Network-based Approach for Apple Leaf Disease Detection in Smart Agriculture Application," 2023. [Online]. Available: www.ijacsa.thesai.org
- [52] H. Ghosh, I. S. Rahat, K. Shaik, S. Khasim, and M. Yesubabu, "Potato Leaf Disease Recognition and Prediction using Convolutional Neural Networks," *EAI Endorsed Transactions on Scalable Information Systems*, vol. 10, no. 6, 2023, doi: 10.4108/eetsis.3937.
- [53] M. Dong, H. Yu, L. Zhang, Y. Sui, and R. Zhao, "A PCA-SMO Based Hybrid Classification Model for Predictions in Precision Agriculture," *Tehnicki Vjesnik*, vol. 30, no. 5, pp. 1652–1660, 2023, doi: 10.17559/TV-20230530000682.
- [54] A. Anbumozhi, "Leaf Diseases Identification and Classification of Self-Collected Dataset on Groundnut Crop using Progressive Convolutional Neural Network (PGCNN)," 2023. [Online]. Available: www.ijacsa.thesai.org
- [55] A. Saeed, A. A. Abdel-Aziz, A. Mossad, M. A. Abdelhamid, A. Y. Alkhaled, and M. Mayhoub, "Smart Detection of Tomato Leaf Diseases Using Transfer Learning-Based Convolutional Neural Networks," *Agriculture (Switzerland)*, vol. 13, no. 1, Jan. 2023, doi: 10.3390/agriculture13010139.
- [56] T. O'Halloran, G. Obaido, B. Otegbade, and I. D. Mienye, "A deep learning approach for Maize Lethal Necrosis and Maize Streak Virus disease detection," *Machine Learning with Applications*, vol. 16, p. 100556, Jun. 2024, doi: 10.1016/j.mlwa.2024.100556.
- [57] J. R. Regazzo et al., "Performance of Neural Networks in the Prediction of Nitrogen Nutrition in Strawberry Plants," *AgriEngineering*, vol. 6, no. 2, pp. 1760–1770, Jun. 2024, doi: 10.3390/agriengineering6020102.
- [58] C. Ünal, "Incorporating Deep Learning into the Diagnosis of Banana Leaf Spot Diseases for the Protection of Banana Crops," *Tarım Bilimleri Dergisi*, vol. 31, no. 3, pp. 780–794, Jul. 2025, doi: 10.15832/ankutbd.1579442.
- [59] W. Agustiono, K. E. Permana, C. Chan, D. A. Dewi, and M. M. R. Al Husain, "Rice Variety Identification Based on Transfer Learning Architecture Using DENS-INCEP," *IEEE Access*, vol. 13, pp. 78007–78020, 2025, doi: 10.1109/ACCESS.2025.3562585.
- [60] S. Chaudhari, A. Rane, and A. R. Kumar, "Personalizing nutrition and recipe recommendation using attention mechanism with an ensemble model," *Clinical eHealth*, vol. 8, pp. 66–77, Dec. 2025, doi: 10.1016/j.ceh.2025.03.002.
- [61] A. M. S. Kheir, A. Koubaa, V. Kolluru, S. Mungara, and T. Feike, "Smart plant disease diagnosis using multiple deep learning and web application integration," *J. Agric. Food Res.*, vol. 21, Jun. 2025, doi: 10.1016/j.jafr.2025.101948.
- [62] M. A. Kurek, H. Aktaş, P. Pokorski, E. Pogorzelska-Nowicka, and J. A. Custodio-Mendoza, "A Comprehensive Review of Analytical Approaches for Carotenoids Assessment in Plant-Based Foods: Advances, Applications, and Future Directions," Apr. 01, 2025, Multidisciplinary Digital Publishing Institute (MDPI). doi: 10.3390/app15073506.
- [63] R. Qasrawi et al., "The impact of online food delivery applications on dietary pattern disruption in the Arab region," *Front. Public Health*, vol. 13, 2025, doi: 10.3389/fpubh.2025.1569945.
- [64] H. G. Ulusoy-Gezer and N. Rakıcıoğlu, "The Future of Obesity Management through Precision Nutrition: Putting the Individual at the Center," Sep. 01, 2024, Springer. doi: 10.1007/s13668-024-00550-y.
- [65] X. Wang, G. Polder, M. Focker, and C. Liu, "Sága, a Deep Learning Spectral Analysis Tool for Fungal Detection in Grains—A Case Study to Detect Fusarium in Winter Wheat," *Toxins (Basel)*, vol. 16, no. 8, Aug. 2024, doi: 10.3390/toxins16080354.

- [66] H. Wang et al., "Nutritional composition analysis in food images: an innovative Swin Transformer approach," *Front. Nutr.*, vol. 11, 2024, doi: 10.3389/fnut.2024.1454466.
- [67] A. Hessane, M. K. Boutahir, A. El Youssefi, Y. Farhaoui, and B. Aghoutane, "Empowering Date Palm Disease Management with Deep Learning: A Comparative Performance Analysis of Pretrained Models for Stage-wise White-Scale Disease Classification," *Data and Metadata*, vol. 2, Jan. 2023, doi: 10.56294/dm2023102.
- [68] J. Sultana, B. M. Ahmed, M. M. Masud, A. K. O. Huq, M. E. Ali, and M. Naznin, "A Study on Food Value Estimation From Images: Taxonomies, Datasets, and Techniques," 2023, Institute of Electrical and Electronics Engineers Inc. doi: 10.1109/ACCESS.2023.3274475.
- [69] D. G. Ayalde et al., "AI-powered detection and quantification of post-harvest physiological deterioration (PPD) in cassava using YOLO foundation models and K-means clustering," *Plant Methods*, vol. 20, no. 1, Dec. 2024, doi: 10.1186/s13007-024-01309-w.
- [70] M. S. Ahmed and S. M. Jeba, "SalmonScan: A novel image dataset for machine learning and deep learning analysis in fish disease detection in aquaculture," *Data Brief*, vol. 54, Jun. 2024, doi: 10.1016/j.dib.2024.110388.
- [71] G. M. Setegn and B. E. Dejene, "Improving machine learning models through explainable AI for predicting the level of dietary diversity among Ethiopian preschool children," *Ital. J. Pediatr.*, vol. 51, no. 1, Dec. 2025, doi: 10.1186/s13052-025-01892-1.
- [72] Y. Yu, X. Huang, D. Lv, B. K. Ng, and C. T. Lam, "A Novel Approach to Pine Nut Classification: Combining Near-Infrared Spectroscopy and Image Shape Features with Soft Voting-Based Ensemble Learning," *Mathematics*, vol. 13, no. 12, Jun. 2025, doi: 10.3390/math13122009.
- [73] M. Anjum, R. Saher, and M. N. Saeed, "Optimizing type 2 diabetes management: AI-enhanced time series analysis of continuous glucose monitoring data for personalized dietary intervention," *PeerJ Comput. Sci.*, vol. 10, 2024, doi: 10.7717/PEERJ-CS.1971.
- [74] H. You, M. Zhou, J. Zhang, W. Peng, and C. Sun, "Sugarcane nitrogen nutrition estimation with digital images and machine learning methods," *Sci. Rep.*, vol. 13, no. 1, Dec. 2023, doi: 10.1038/s41598-023-42190-2.
- [75] A. Phalle and D. Gokhale, "Navigating next-gen nutrition care using artificial intelligence-assisted dietary assessment tools—a scoping review of potential applications," 2025, *Frontiers Media SA*. doi: 10.3389/fnut.2025.1518466.
- [76] L. Montaina, E. Palmieri, I. Lucarini, L. Maiolo, and F. Maita, "Toward a User-Accessible Spectroscopic Sensing Platform for Beverage Recognition Through K-Nearest Neighbors Algorithm," *Sensors*, vol. 25, no. 14, Jul. 2025, doi: 10.3390/s25144264.
- [77] R. D. Riley et al., "Importance of sample size on the quality and utility of AI-based prediction models for healthcare," *Jun. 01, 2025, Elsevier Ltd.* doi: 10.1016/j.landig.2025.01.013.
- [78] Y. Feng, Y. Wang, X. Wang, J. Bi, Z. Xiao, and Y. Luo, "Large-scale image classification and nutrient estimation for Chinese dishes," *J. Agric. Food Res.*, vol. 19, Mar. 2025, doi: 10.1016/j.jafr.2025.101733.
- [79] A. Abeltino et al., "Digital applications for diet monitoring, planning, and precision nutrition for citizens and professionals: a state of the art," Feb. 01, 2025, Oxford University Press. doi: 10.1093/nutrit/nuae035.
- [80] R. Bianco et al., "Tailoring the Nutritional Composition of Italian Foods to the US Nutrition5k Dataset for Food Image Recognition: Challenges and a Comparative Analysis," *Nutrients*, vol. 16, no. 19, Oct. 2024, doi: 10.3390/nu16193339.
- [81] M. Tufano, M. P. Lasschuijt, A. Chauhan, E. J. M. Feskens, and G. Camps, "Rule-based systems to automatically count bites from meal videos," *Front. Nutr.*, vol. 11, 2024, doi: 10.3389/fnut.2024.1343868.
- [82] Y. Han, J. He, M. Gupta, E. J. Delp, and F. Zhu, "Diffusion Model with Clustering-based Conditioning for Food Image Generation," in *MADiMa 2023 - Proceedings of the 8th International Workshop on Multimedia Assisted Dietary Management*, Co-located with: MM 2023, Association for Computing Machinery, Inc, Oct. 2023, pp. 61–69. doi: 10.1145/3607828.3617796.
- [83] H. Sun et al., "An AI Dietitian for Type 2 Diabetes Mellitus Management Based on Large Language and Image Recognition Models: Preclinical Concept Validation Study," *J. Med. Internet Res.*, vol. 25, 2023, doi: 10.2196/51300.
- [84] A. Sanatbyek et al., "A Multitask Deep Learning Model for Food Scene Recognition and Portion Estimation—the Food Portion Benchmark (FPB) Dataset," *IEEE Access*, vol. 13, pp. 152033–152045, 2025, doi: 10.1109/ACCESS.2025.3603287.
- [85] J. You, D. Tulpan, C. Krzyżek, and J. L. Ellis, "Prediction of Pellet Durability Index in a commercial feed mill using multiple linear regression with variable selection and dimensionality reduction," *J. Anim. Sci.*, vol. 103, 2025, doi: 10.1093/jas/skaf021.