

# Automatización inteligente en el cultivo de setas: revisión sobre la aplicación de procesamiento de imágenes desde la investigación hasta la producción

Oscar L. Espinoza-Alvarez<sup>1</sup>, Nilton de J. Carbajal-Palacios<sup>1</sup>, Oscar A. Flores-Amaro<sup>2</sup>, Francisco Villanueva-Mejía<sup>1</sup>, Miguel S. Soriano-García<sup>3</sup> y Pamela Romo-Rodríguez<sup>1\*</sup>

<sup>1</sup> Tecnológico Nacional de México Campus Pabellón de Arteaga, Carretera a la Estación de Rincón Km 1, C.P. 20670 Pabellón de Arteaga, Ags., México, oscar.ea@pabellon.tecnm.mx, nilton.cp@pabellon.tecnm.mx, francisco.villanueva@pabellon.tecnm.mx

<sup>2</sup> Universidad Autónoma de Aguascalientes, Av. Universidad 940, C.P. 20100 Aguascalientes, Ags., México, oscar.flores@edu.uaa.mx

<sup>3</sup> Centro de Investigación en Matemáticas Unidad Zacatecas, Calle Lasec y Andador Galileo Galilei Manzana 3 Lote 7 Quantum Ciudad del Conocimiento, C.P. 98160, Zacatecas, Zac., México, miguel.garcia@cimat.mx

\*Autor de correspondencia: pamela.rr@pabellon.tecnm.mx

## Resumen

El cultivo de setas comestibles es una actividad de creciente importancia en la industria alimentaria y la biotecnología debido a su alto valor nutricional y su potencial en la producción de compuestos bioactivos. Sin embargo, la producción enfrenta múltiples desafíos, desde la selección de sustratos hasta el control de contaminantes. La automatización mediante procesamiento de imágenes se presenta como una solución innovadora para optimizar fases de cultivo, permitiendo un monitoreo preciso y en tiempo real de los parámetros críticos. Para la elaboración de esta revisión se realizó un análisis sistemático de la literatura científica publicada entre 2013 y 2025, considerando estudios indexados en bases de datos especializadas y clasificándolos de acuerdo con su enfoque tecnológico y biológico. De la literatura analizada, más del 60 % de los estudios reportan incrementos de eficiencia superiores al 30 % en la detección de contaminantes o en la estimación de crecimiento micelial mediante visión por computadora, mientras que un 45 % de las investigaciones recientes aplican redes neuronales convolucionales (CNN) para la segmentación y clasificación automática de imágenes fúngicas. Este artículo aborda, a manera de revisión, la aplicación del procesamiento de imágenes en la automatización del cultivo de setas comestibles, explorando sus beneficios en cada etapa del proceso productivo y analizando el potencial de las tecnologías actuales y emergentes para transformar la producción de hongos a escala industrial.

**Palabras clave**— Automatización, cultivo de setas, procesamiento de imágenes, tecnologías emergentes.

## A smart automation in mushroom cultivation: a review on the application of image processing from research to production

### Abstract

The cultivation of edible mushrooms is an increasingly important activity in the food industry and biotechnology due to their high nutritional value and potential in the production of bioactive compounds. However, production faces multiple challenges, from substrate selection to contaminant control. Automation through image processing presents an innovative solution to optimize cultivation phases, allowing precise and real-time monitoring of critical parameters. For the preparation of this review, a systematic analysis of the scientific literature published between 2013 and 2025 was conducted, considering studies indexed in specialized databases and classifying them according to their technological and biological focus. According to the reviewed literature, over 60 % of studies reported efficiency increases above 30 % in contaminant detection or mycelial growth estimation using computer vision, while 45 % of recent works implemented convolutional neural networks (CNNs) for automated fungal image segmentation and classification. This article addresses, as a review, the application of image processing in the automation of edible mushroom cultivation, exploring its benefits at each stage of the production process and analyzing the potential of current and emerging technologies to transform mushroom production on an industrial scale.

**Keywords**— Automation, emerging technologies, image processing, mushroom cultivation.

### I. INTRODUCCIÓN

El cultivo de setas comestibles es una actividad de creciente importancia en la industria alimentaria y la biotecnología debido a su alto valor nutricional, su versatilidad en la gastronomía y su potencial en la producción de compuestos bioactivos con aplicaciones en la salud y la industria farmacéutica [1]-[3]. Especies como *Pleurotus ostreatus*,

*Agaricus bisporus* y *Lentinula edodes* han sido ampliamente estudiadas y cultivadas a nivel industrial debido a su demanda en mercados nacionales e internacionales [3], [4]. Además, este tipo de cultivo juega un papel crucial en la economía circular, ya que permite el aprovechamiento de residuos agrícolas como sustratos de crecimiento [4], [5].

No obstante, la producción de setas enfrenta múltiples desafíos, desde la selección de sustratos con alto rendimiento

hasta el control de contaminantes y la optimización de las condiciones de crecimiento [6]. Tradicionalmente, estas tareas han dependido de la observación manual y la experiencia de los productores, lo que puede llevar a variabilidad en la calidad y eficiencia del cultivo [7]. En este contexto, el cultivo de setas comestibles representa un campo emergente donde estas tecnologías pueden contribuir al control automatizado de variables críticas, como la inoculación, el monitoreo de crecimiento micelial, la detección de contaminantes y la clasificación postcosecha. Aunque la mayoría de los avances tecnológicos se han enfocado en cultivos vegetales, en años recientes se han reportado investigaciones orientadas directamente al uso de procesamiento de imágenes en hongos. Entre ellas se incluyen estudios que implementan reconocimiento de imágenes para el control de inoculación en *Pleurotus eryngii*, algoritmos de medición in situ basados en redes neuronales para *Oudemansiella raphanipies*, y la generación de bases de datos anotadas de imágenes de *P. ostreatus* con fines de aprendizaje automático [7–9]. Estos trabajos evidencian que la automatización mediante visión artificial en hongos no solo es posible, sino que constituye una tendencia científica en expansión, con implicaciones directas en la mejora de la eficiencia, la estandarización de procesos y la reducción de la dependencia del monitoreo manual.

El procesamiento de imágenes ha transformado diversos sectores de la producción agrícola. En cultivos de gran escala como el manzano, el maíz y la vid, se emplean cámaras multispectrales y modelos de visión artificial para la detección temprana de enfermedades [10]–[12], el monitoreo de la salud de las plantas y la optimización del riego en función de la humedad del suelo [13], [14]. En la cosecha de frutas como fresas y tomates, se han implementado sistemas de recolección automatizada que utilizan visión por computadora para identificar el estado de maduración y clasificar los frutos según su calidad [15], [16]. En la industria avícola, el procesamiento de imágenes se emplea para la detección de defectos en los huevos y la supervisión del bienestar de las aves en tiempo real [17], [18].

En el caso del cultivo de setas, estas tecnologías pueden ser aplicadas para mejorar la producción de manera significativa. Por ejemplo, el uso de algoritmos de aprendizaje profundo, los cuales ya han sido utilizados en el análisis de imágenes satelitales para la detección de cambios en la cobertura del suelo y en el diagnóstico automatizado de enfermedades en hojas de cultivos como el tomate [19], [20], podría facilitar la identificación de los sustratos con mejor desempeño en términos de colonización micelial. La visión artificial, ampliamente utilizada en la industria alimentaria para la inspección de calidad de alimentos, herramientas de control y clasificación de los alimentos [21], podría ser aplicada para la detección de contaminación en medios de cultivo mediante el análisis de imágenes de placas de Petri y sustratos inoculados.

Durante la incubación, sensores ópticos similares a los empleados en invernaderos inteligentes [22] pueden integrarse con algoritmos de procesamiento de imágenes para monitorear la expansión del micelio, permitiendo ajustes automáticos en la temperatura y humedad del ambiente. En la fase de

fructificación, cámaras hiperespectrales, las cuales han sido utilizadas para evaluar el contenido de azúcar y la firmeza en frutas como manzanas y melones [23], podrían emplearse para monitorear el crecimiento y determinar el momento óptimo de cosecha de los cuerpos fructíferos. La automatización de la cosecha, ya implementada en la recolección de hortalizas como lechugas y espárragos mediante robots equipados con visión por computadora [24], [25], podría adaptarse al cultivo de setas para reducir la manipulación manual y aumentar la eficiencia del proceso.

Además, el Internet de las Cosas (IoT) ha sido ampliamente aplicado en la supervisión en tiempo real de maquinaria agrícola y en la gestión eficiente de recursos hídricos en cultivos de precisión [26]. En la producción de setas, esta tecnología podría utilizarse para conectar sensores de imagen con sistemas de control automatizados que optimicen las condiciones ambientales y minimicen el desperdicio de insumos. La integración de redes neuronales, utilizadas en la clasificación automatizada de productos en la industria manufacturera [27], permitiría la detección de anomalías en las setas, facilitando su clasificación y mejorando la calidad del producto final.

Este artículo aborda, a manera de revisión, la aplicación del procesamiento de imágenes en la automatización del cultivo de setas comestibles, explorando sus beneficios en cada etapa del proceso productivo y analizando el potencial de las tecnologías actuales y emergentes para transformar la producción de hongos a escala industrial.

## II. METODOLOGÍA

La presente investigación se desarrolló como una revisión sistemática orientada a analizar el estado actual del conocimiento sobre la aplicación del procesamiento de imágenes y las tecnologías de automatización en el cultivo de hongos comestibles. Para ello, se efectuó una búsqueda exhaustiva de información científica publicada entre 2013 y 2025, considerando artículos de investigación, revisiones, reportes técnicos y ponencias en conferencias especializadas. Las fuentes consultadas incluyeron bases de datos académicas de alto impacto como Scopus, Web of Science, y Google Scholar, con el propósito de garantizar la calidad, actualidad y relevancia de las referencias seleccionadas.

Las búsquedas se realizaron empleando combinaciones de palabras clave en inglés y español tales como “mushroom cultivation”, “image processing”, “computer vision”, “automation”, “artificial intelligence”, “deep learning”, “IoT agriculture” y “fungal growth monitoring”. Se priorizó la recuperación de estudios que presentaran aplicaciones directas o potencialmente adaptables al cultivo de setas, así como aquellos que describieran metodologías de análisis de imágenes, sistemas de control automatizado o estrategias de monitoreo ambiental mediante visión artificial y aprendizaje automático.

Inicialmente se identificaron más de 180 publicaciones relacionadas con los temas de automatización agrícola, biotecnología fúngica y procesamiento digital de imágenes. Posteriormente, se aplicaron criterios de inclusión y exclusión

enfocados en la pertinencia metodológica, la disponibilidad de información completa y la claridad en la descripción de los procedimientos empleados. Solo se consideraron artículos revisados por pares y publicados en revistas o editoriales científicas reconocidas. Tras esta depuración, se seleccionaron 68 documentos que constituyeron el cuerpo principal de análisis.

Las publicaciones seleccionadas se organizaron en tres líneas temáticas: (1) identificación, comparación y caracterización de sustratos mediante procesamiento de imágenes; (2) automatización de procesos de inoculación e incubación a partir de sistemas de visión artificial, sensores ópticos y redes neuronales; y (3) monitoreo, cosecha y postcosecha automatizadas utilizando técnicas de visión hiperespectral, robótica y aprendizaje profundo. Dentro de cada categoría se examinaron las metodologías implementadas, los tipos de sensores o cámaras empleados, los algoritmos de segmentación y clasificación, así como las aplicaciones específicas reportadas para distintas especies de hongos comestibles.

Asimismo, se revisaron estudios provenientes de áreas afines, como la agricultura de precisión, la microbiología y la ingeniería agroalimentaria, con el fin de identificar metodologías extrapolables al cultivo de setas. Este enfoque permitió establecer relaciones entre los avances tecnológicos en distintos sectores productivos y su posible adaptación a la biotecnología fúngica.

Cabe destacar que las Fig. 1 y 2 incluidas en este trabajo provienen de datos sin publicar, generados por el grupo de investigación de los autores, y se presentan únicamente con fines ilustrativos para mostrar el potencial del procesamiento de imágenes en la evaluación del crecimiento micelial y la detección de contaminantes. Dichos datos fueron obtenidos en condiciones controladas y aún no han sido sometidos a publicación formal, pero su inclusión contribuye a ejemplificar los alcances prácticos de las herramientas analizadas en esta revisión.

La información obtenida de las fuentes seleccionadas fue analizada de manera crítica y comparativa, destacando los enfoques metodológicos más sólidos, las tecnologías emergentes con mayor aplicabilidad y los retos identificados para su integración en sistemas de producción de hongos a escala industrial. El análisis cualitativo permitió identificar tendencias generales, vacíos de conocimiento y posibles líneas de investigación futura orientadas hacia la consolidación de sistemas inteligentes para el cultivo de setas comestibles.

### III. IDENTIFICACIÓN, COMPARACIÓN Y CARACTERIZACIÓN DE SUSTRATOS ÓPTIMOS

El éxito en la producción de setas comestibles depende en gran medida de la selección del sustrato adecuado, ya que este influye en la velocidad de colonización micelial, la eficiencia en la producción de cuerpos fructíferos y la resistencia a contaminantes [28]. Tradicionalmente, la evaluación de sustratos ha sido un proceso empírico basado en observaciones manuales, lo que genera variabilidad y limita la reproducibilidad de los resultados [29], [30]. Sin embargo, la

automatización mediante procesamiento de imágenes y aprendizaje automático ofrece un enfoque más preciso para analizar las propiedades físicas y químicas del sustrato, optimizando así la toma de decisiones en el proceso productivo.

El procesamiento de imágenes ha sido ampliamente utilizado en la caracterización de materiales agrícolas en distintos ámbitos. En la industria de los cereales, se emplea para identificar defectos en los granos y evaluar su calidad visual [31]-[33]; en la industria forestal, se usa para determinar la porosidad de la madera y la detección de incendios forestales [34], [35]; y en la producción de hortalizas, se ha implementado en sistemas de clasificación automática basados en color, forma y textura [36]. Aplicando estas mismas metodologías al cultivo de setas, se esperaría poder caracterizar sustratos a partir de imágenes de alta resolución, identificando parámetros como textura, distribución de partículas, retención de agua y colonización micelial mediante técnicas de segmentación y análisis de patrones.

Diversos estudios han explorado el impacto de diferentes sustratos en el crecimiento de setas, empleando herramientas automatizadas para evaluar su eficiencia. La Tabla 1 presenta un resumen de investigaciones previas sobre la caracterización de sustratos mediante procesamiento de imágenes y otras técnicas automatizadas.

TABLA I  
METODOLOGÍAS DE ANÁLISIS DE IMÁGENES EN LA EVALUACIÓN DE SUSTRATOS FÚNGICOS

Especie	Sustratos evaluados	Método de análisis	Ref.
<i>Beauveria bassiana</i> , <i>Trichoderma harzianum</i>	Cáscara de arroz, naranja, papa, pulpa, bagazo, fibras, paja	Microscopía óptica	[37]
<i>Micena</i> , <i>Boletus</i> , <i>Exidia</i>	Madera, corteza, suelo, fruta, musgo, piedra	CNN y ViT	[38]
<i>Pleurotus geesteranus</i>	Cáscara de Camellia oleífera	Estadística de imágenes	[39]
<i>Pleurotus ostreatus</i> , <i>Coprinus comatus</i>	Paja	Lightroom + Python	[40]
<i>Ganoderma resinaceum</i>	Flores de rosa, paja de lavanda	Microscopía electrónica	[41]
<i>Candida spp.</i> , <i>Aspergillus spp.</i> , <i>Trichophyton</i> , <i>Rhizopus</i>	Sustratos + nanopartículas metálicas	SERS + PCA y LDA	[42]
<i>Candida auris</i> , <i>Candida albicans</i>	BHI, agar SD, RPMI 1640	Espectroscopia Raman	[43]
<i>Schizophyllum commune</i>	Medios con glucosa 0.1% y 3.9%	Imágenes en escala de grises	[44]
<i>Fomes fomentarius</i> , <i>Ganoderma spp.</i> , etc.	Cuerpos fructíferos, esclerocios	Algoritmo Watershed	[45]
<i>P. ostreatus</i>	Aserrín, agua, cal, ceniza de biomasa	Imágenes + CNN	[27]

Estos estudios destacan cómo el procesamiento de imágenes puede ser una herramienta clave en la identificación y comparación de sustratos, permitiendo una evaluación objetiva y cuantificable de sus propiedades. Además, el uso de inteligencia artificial ha demostrado ser eficaz para predecir la productividad de los cultivos en función de los parámetros fenotípicos de los cuerpos fructíferos [46].

El procesamiento de imágenes facilita la toma de decisiones en la selección de sustratos al proporcionar datos cuantificables sobre el crecimiento micelial y su uniformidad. En la Fig. 1, se presenta la evaluación del desarrollo micelial en un medio de cultivo estándar, como lo es el Agar Papa Dextrosa, utilizando segmentación y detección de bordes para identificar la expansión del micelio a lo largo de 7 días; este análisis permite una evaluación objetiva de la tasa de colonización y la uniformidad del crecimiento, facilitando la optimización de las condiciones de incubación.




Fig. 1. Evaluación del crecimiento micelial en un medio de cultivo estándar (PDA) mediante procesamiento de imágenes. Se muestra la expansión del micelio a lo largo de A) 1, B) 2, C) 5 y D) 7 días, con segmentación y detección de bordes (línea verde) para cuantificar su desarrollo (N. J. Carbajal-Palacios, comunicación personal, junio 2025).

Este enfoque podría permitir el analizar patrones de crecimiento, evaluar la tasa de colonización y detectar posibles anomalías en el desarrollo fúngico. La integración de estas técnicas con algoritmos de aprendizaje automático no solo optimizaría la selección del sustrato más eficiente, sino que también permitiría la generación de modelos predictivos que faciliten futuras optimizaciones en la producción de setas. Al reducir el tiempo de experimentación y minimizar la variabilidad en los resultados, la combinación de procesamiento de imágenes e inteligencia artificial representa un avance significativo hacia la automatización del cultivo, mejorando la eficiencia y sostenibilidad del proceso productivo.

#### IV. AUTOMATIZACIÓN EN LA INOCULACIÓN E INCUBACIÓN

La fase de inoculación e incubación es crucial en la producción de setas comestibles, ya que durante estos procesos se determina el éxito de la colonización del sustrato por parte del micelio y la prevención de contaminantes que puedan afectar el rendimiento del cultivo [47], [48]. Tradicionalmente, el monitoreo de la colonización micelial y la detección de contaminantes se ha basado en inspecciones visuales manuales, lo que introduce un alto grado de variabilidad en la evaluación y puede retrasar la detección temprana de problemas [49]. Sin

embargo, la implementación de sistemas de automatización mediante el procesamiento de imágenes, el aprendizaje automático y sensores de monitoreo ambiental puede permitir optimizar estos procesos, aumentando la eficiencia y reduciendo pérdidas en la producción.

El procesamiento de imágenes ha sido utilizado ampliamente en la microbiología y la agricultura para el análisis y diferenciación de organismos en medios de cultivo. En la industria biomédica, por ejemplo, la segmentación de imágenes se emplea para identificar colonias bacterianas en placas de Petri, permitiendo un diagnóstico más rápido de infecciones [50], [51]. De manera similar, en la agricultura de precisión, la visión por computadora es utilizada para diferenciar entre plagas y cultivos saludables mediante el reconocimiento de patrones y colores específicos en hojas y frutos [52], [53]. Aplicando estas mismas metodologías al cultivo de setas, es posible desarrollar sistemas capaces de distinguir entre el crecimiento del micelio y la presencia de organismos contaminantes en el sustrato.

Un ejemplo de esta aplicación en el cultivo de hongos se observa en la Fig. 2, donde se muestra la diferenciación entre la expansión del micelio y la presencia de un organismo contaminante mediante segmentación de imágenes y análisis de textura. En esta imagen, la segmentación basada en umbrales de intensidad y análisis de bordes permite resaltar la estructura del micelio, diferenciándolo de colonias bacterianas o fúngicas indeseadas. Este enfoque facilita la detección temprana de contaminaciones, permitiendo la implementación de estrategias correctivas antes de que comprometan la totalidad del cultivo.




Fig. 2. Diferenciación entre el crecimiento del micelio y la presencia de un organismo contaminante mediante procesamiento de imágenes. Se emplearon técnicas de segmentación y análisis de textura para resaltar la estructura del micelio y distinguirlo de colonias contaminantes (O. L. Espinoza-Alvarez, comunicación personal, junio 2025).

Además de la diferenciación visual, la integración de sensores ópticos y espectroscópicos en los sistemas de monitoreo de la incubación ha demostrado ser efectiva para evaluar parámetros ambientales críticos como la temperatura, la humedad y la concentración de CO<sub>2</sub> [54]-[57]. Tecnologías como la espectroscopia de infrarrojo cercano (NIR), utilizada en la industria alimentaria para evaluar la calidad de productos agrícolas [58], [59], pueden aplicarse en el monitoreo de la actividad metabólica del micelio, proporcionando información en tiempo real sobre su estado fisiológico y su tasa de crecimiento.

Otra innovación clave en la automatización de la incubación es el uso de modelos de aprendizaje profundo para predecir la velocidad de colonización del micelio en función de imágenes capturadas a lo largo del tiempo. En la industria láctea, por ejemplo, estos modelos han sido empleados para monitorear la fermentación de productos como el yogur y el queso, permitiendo ajustar las condiciones de incubación en función del desarrollo microbiano [60], [61]. En el caso de los hongos, esta tecnología podría estimar el tiempo óptimo de incubación y ajustar variables ambientales de manera automatizada, asegurando un crecimiento uniforme y reduciendo la variabilidad entre lotes de producción.

En conjunto, la implementación de procesamiento de imágenes, sensores ambientales y algoritmos de inteligencia artificial en la inoculación e incubación de setas no solo optimizaría la detección de contaminantes y la evaluación del crecimiento micelial, sino que también contribuirían a la estandarización del proceso productivo. Estas tecnologías permitirían reducir la dependencia de la inspección manual, mejorar la trazabilidad del cultivo y garantizar condiciones óptimas para el desarrollo de las setas, promoviendo así una producción más eficiente y sostenible.

#### V. DESARROLLO, COSECHA Y POSTCOSECHA MEDIANTE PROCESAMIENTO DE IMÁGENES

El monitoreo del crecimiento y desarrollo de los cuerpos fructíferos, así como la optimización de los procesos de cosecha y postcosecha, son aspectos fundamentales en la producción de setas comestibles [7], [8]. La calidad del producto final depende de múltiples factores, incluyendo la morfología de los cuerpos fructíferos, la uniformidad en el desarrollo, el punto óptimo de cosecha y las condiciones de almacenamiento [62]. Tradicionalmente, estas etapas han requerido inspección visual y manipulación manual, lo que introduce variabilidad y aumenta los costos de producción [55]. Sin embargo, la implementación de técnicas de procesamiento de imágenes, inteligencia artificial y automatización podrían mejorar la eficiencia y precisión en cada una de estas fases, facilitando una producción más estandarizada y de mayor calidad.

El procesamiento de imágenes se ha aplicado en la industria agrícola para el análisis de crecimiento y maduración de diferentes productos [63]. En cultivos como el tomate y la manzana, la visión artificial es utilizada para evaluar el tamaño y el color de los frutos, asegurando que la cosecha se realice en el momento óptimo [63], [64]. En la producción de setas, estos mismos principios podrían aplicarse para monitorear la morfología de los cuerpos fructíferos a lo largo de su desarrollo, permitiendo la detección de irregularidades y la predicción del punto exacto de cosecha.

Uno de los enfoques más prometedores en este ámbito es el uso de cámaras multispectrales para evaluar el estado fisiológico de las setas en tiempo real. Estas cámaras, ampliamente utilizadas en el control de calidad de productos hortofrutícolas, permiten analizar la composición de la superficie de los cuerpos fructíferos y detectar defectos no visibles al ojo humano [63]. Aplicadas al cultivo de hongos,

pueden emplearse para identificar problemas como deshidratación, decoloración o daños estructurales antes de la cosecha, optimizando así la selección de productos de alta calidad.

Además del monitoreo del crecimiento, el procesamiento de imágenes ha sido clave en la automatización de la cosecha de productos agrícolas de alto valor, como las fresas y los espárragos, mediante sistemas robóticos equipados con visión por computadora [65], [66]. En el caso de las setas, esta tecnología permitiría el desarrollo de sistemas de recolección automática capaces de identificar el tamaño, forma y madurez de los cuerpos fructíferos, reduciendo la manipulación manual y minimizando el riesgo de daño al producto.

En la postcosecha, la visión artificial podría jugar un papel crucial en el control de calidad y clasificación de las setas antes de su comercialización. Técnicas como el análisis hiperespectral, utilizadas en la industria cárnica para evaluar la frescura de la carne [67], pueden aplicarse en la producción de hongos para detectar signos tempranos de descomposición o contaminación. Del mismo modo, algoritmos de reconocimiento de patrones pueden emplearse para clasificar las setas según su tamaño y textura, asegurando un producto homogéneo y atractivo para el mercado. Un ejemplo de esta aplicación se encuentra en la industria citrícola, donde sistemas de visión artificial son utilizados para clasificar naranjas y limones en función de su diámetro y uniformidad de la cáscara, descartando aquellos con defectos superficiales [64], [68]. Aplicando esta tecnología en la producción de setas, se pueden desarrollar sistemas automatizados que evalúen la forma y firmeza de los cuerpos fructíferos, identificando aquellos que cumplen con los estándares de calidad y separándolos de los especímenes que presenten irregularidades o signos de descomposición.

En conjunto, la integración de procesamiento de imágenes, aprendizaje automático y robótica en la producción de setas ofrece un enfoque innovador para mejorar la eficiencia y calidad del producto final. Estas herramientas no solo permiten reducir la variabilidad en la producción, sino que también abren nuevas oportunidades para la automatización de procesos clave, desde el monitoreo del crecimiento hasta la clasificación postcosecha, asegurando una producción más rentable, sostenible y adaptada a los estándares de calidad del mercado global.

#### VI. ANÁLISIS DE INFORMACIÓN Y PERSPECTIVAS FUTURAS

El uso de procesamiento de imágenes y automatización en el cultivo de setas comestibles representa un área con gran potencial de desarrollo tecnológico, aunque aún se encuentra en una etapa inicial de aplicación. Estas herramientas pueden contribuir significativamente a la optimización de cada fase del proceso productivo, desde la inoculación hasta la postcosecha, mejorando la eficiencia, reduciendo la variabilidad y favoreciendo la obtención de un producto final de mayor calidad.

Actualmente, gran parte de las actividades en el cultivo de setas dependen de la inspección visual y de la experiencia del

productor, lo que introduce un componente subjetivo que dificulta la estandarización. La Fig. 3 compara los métodos manuales con los procesos automatizados mediante procesamiento de imágenes, mostrando cómo estas tecnologías permiten una toma de decisiones más precisa y objetiva. Desde la detección de uniformidad en la inoculación del sustrato hasta la clasificación automatizada en la postcosecha, la visión por computadora ofrece la posibilidad de optimizar cada una de las etapas productivas, minimizando la manipulación manual y aumentando la productividad general del sistema.

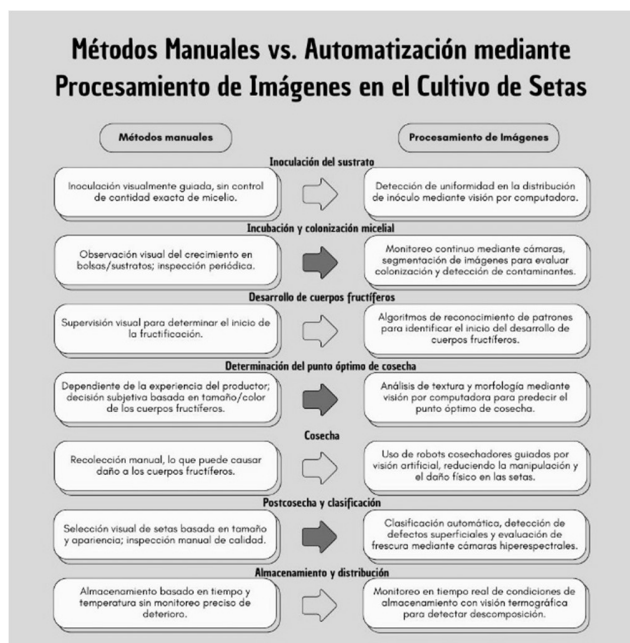


Fig. 3. Comparación entre el método manual y la implementación de procesamiento de imágenes en el cultivo de setas. Elaboración propia.

La implementación de técnicas como la segmentación de imágenes y los modelos predictivos basados en aprendizaje automático podría facilitar la selección de sustratos de mejor rendimiento, evitando la dependencia de ensayos prolongados. En la fase de incubación, la diferenciación entre micelio y contaminantes mediante análisis de textura permitiría una respuesta más rápida ante problemas de contaminación. Durante la fructificación, los algoritmos de reconocimiento de patrones pueden ayudar a determinar el momento óptimo de cosecha, mientras que la recolección automatizada mediante visión artificial reduciría el daño mecánico en los cuerpos fructíferos. En la postcosecha, la clasificación basada en cámaras hiperspectrales favorecería la obtención de un producto homogéneo y de alta calidad, facilitando su comercialización.

A futuro, la integración del procesamiento de imágenes con tecnologías emergentes como el IoT, la computación en la nube y la inteligencia artificial aplicada permitirá establecer sistemas de monitoreo remoto en tiempo real. Esto generará entornos productivos inteligentes capaces de tomar decisiones automáticas basadas en datos cuantificables. Además, el desarrollo de modelos de inteligencia artificial especializados en hongos podría mejorar la detección de anomalías, la

predicción del rendimiento y la sostenibilidad de la producción. No obstante, persisten desafíos importantes, entre ellos la accesibilidad tecnológica para pequeños productores, la necesidad de estandarizar metodologías de procesamiento de imágenes adaptadas a diferentes especies fúngicas y la capacitación técnica en el uso de herramientas automatizadas. Superar estas limitaciones será clave para avanzar hacia una automatización efectiva y equitativa en el sector de los hongos comestibles.

## VII. CONCLUSIONES

El objetivo de esta revisión se cumplió al identificar de manera sistemática el estado actual, las tendencias y los vacíos en la aplicación del procesamiento de imágenes y la automatización en el cultivo de setas comestibles. Se evidenció que el área más desarrollada corresponde al monitoreo y control automatizado de la inoculación e incubación, donde predominan los sistemas basados en visión por computadora y CNN aplicadas a la detección de contaminantes y la evaluación del crecimiento micelial.

En contraste, se identifican vacíos en la automatización de la fase de postcosecha y en la integración completa de sistemas inteligentes que vinculen sensores, algoritmos de decisión y control ambiental en tiempo real. Aun así, la tendencia tecnológica dominante se orienta hacia la convergencia de procesamiento de imágenes, aprendizaje profundo e IoT, configurando la base para sistemas de producción inteligentes.

En síntesis, la automatización mediada por visión artificial representa una estrategia viable y de alto impacto para optimizar la producción de setas, reducir la variabilidad y fortalecer la sostenibilidad del proceso. La consolidación de esta línea dependerá de la colaboración interdisciplinaria entre biotecnología, mecatrónica y ciencia de datos, garantizando que los avances tecnológicos sean accesibles y adaptables a distintos contextos productivos.

## REFERENCIAS

- [1] Golak-Siwulska, I., Kałużewicz, A., Spizewski, T., Siwulski, M., & Sobieralski, K. (2018). Bioactive compounds and medicinal properties of Oyster mushrooms (*Pleurotus* sp.). *Folia Horticulturae*, 30(2), 191-201.
- [2] Kadam, P., Yadav, K., Karanje, A., Giram, D., Mukadam, R., & Patil, M. (2023). The food and medicinal benefits of oyster mushroom (*Pleurotus ostreatus*): a review. *International Pharmaceutical Science & Research*, 14(2), 883-890.
- [3] Raman, J., Jang, K. Y., Oh, Y. L., Oh, M., Im, J. H., Lakshmanan, H., & Sabaratnam, V. (2021). Cultivation and nutritional value of prominent *Pleurotus* spp.: an overview. *Mycobiology*, 49(1), 1-14.
- [4] Doroški, A., Klaus, A., Režek Jambrak, A., & Djekic, I. (2022). Food waste originated material as an alternative substrate used for the cultivation of oyster mushroom (*Pleurotus ostreatus*): a review. *Sustainability*, 14(19), 12509.
- [5] Cayetano-Catirino, M., Bernabé-González, T., Bernabé-Villanueva, G., & Romero-Flores, A. (2020). Three-plant stubble (Family: Fabaceae) as a substrate for cultivation of *Pleurotus ostreatus* (Jacq.) P. Kummer., in Mexico. *Journal of Applied and Natural Science*, 12(2), 156-158.
- [6] De Mastro, F., Traversa, A., Matarrese, F., Cocozza, C., & Brunetti, G. (2023). Influence of growing substrate preparation on the biological efficiency of *Pleurotus ostreatus*. *Horticulturae*, 9(4), 439.
- [7] Meng, X., Zhu, X., Ding, Y., & Qi, D. (2021, December). Application of Image Recognition in Precise Inoculation Control System of *Pleurotus Eryngii*. *International Conference on Wireless, Communications, Networking and Applications* (pp. 988-1005). Singapore: Springer Nature

- Singapore.
- [8] Yin, H., Xu, J., Wang, Y., Hu, D., & Yi, W. (2022). A novel method of situ measurement algorithm for oudemansiella raphanipies caps based on YOLO v4 and distance filtering. *Agronomy*, 13(1), 134.
  - [9] Duman, S., Elewi, A., Hajhamed, A., Khankan, R., Souag, A., & Ahmed, A. (2024). A novel dataset of annotated oyster mushroom images with environmental context for machine learning applications. *Data in Brief*, 57, 111074.
  - [10] Abbaspour-Gilandeh Y., Aghabara A., Davari M. & Mari Maja J. (2022). Feasibility of using computer vision and artificial intelligence techniques in detection of some apple pests and diseases. *Appl. Sci.*, 12(2), 906.
  - [11] Nguyen, C., Sagan, V., Maimaitiyiming, M., Maimaitijiang, M., Bhadra, S., & Kwasniewski, M. T. (2021). Early detection of plant viral disease using hyperspectral imaging and deep learning. *Sensors (Switzerland)*, 21(3), 1–23.
  - [12] Kundu, N., Rani, G., Dhaka, V. S., Gupta, K., Nayaka, S. C., Vocaturo, E., & Zumpano, E. (2022). Disease detection, severity prediction, and crop loss estimation in MaizeCrop using deep learning. *Artificial Intelligence in Agriculture*, 6, 276–291.
  - [13] Singh, A., & Gaurav, K. (2023). Deep learning and data fusion to estimate surface soil moisture from multi-sensor satellite images. *Scientific Reports*, 13(1).
  - [14] Dhanya, V. G., Subeesh, A., Kushwaha, N. L., Vishwakarma, D. K., Nagesh Kumar, T., Ritika, G., & Singh, A. N. (2022). Deep learning based computer vision approaches for smart agricultural applications. In *Artificial Intelligence in Agriculture* (Vol. 6, pp. 211–229). KeAi Communications Co.
  - [15] Lemsalu, M., Bloch, V., Backman, J., & Pastell, M. (2022). Real-Time CNN-based Computer Vision System for Open-Field Strawberry Harvesting Robot. *IFAC-PapersOnLine*, 55(32), 24–29.
  - [16] Zhaoxin, G., Han, L., Zhijiang, Z., & Libo, P. (2022). Design a Robot System for Tomato Picking Based on YOLO v5. *IFAC-PapersOnLine*, 55(3), 166–171.
  - [17] Nakrosis, A., Paulauskaite-Taraseviciene, A., Raudonis, V., Narusis, I., Gruzauskas, V., Gruzauskas, R., & Lagzdinyte-Budnike, I. (2023). Towards Early Poultry Health Prediction through Non-Invasive and Computer Vision-Based Dropping Classification. *Animals*, 13(19).
  - [18] Yang, X., Bist, R. B., Subedi, S., & Chai, L. (2023). A Computer Vision-Based Automatic System for Egg Grading and Defect Detection. *Animals*, 13(14).
  - [19] Naushad, R., Kaur, T., & Ghaderpour, E. (2021). Deep transfer learning for land use and land cover classification: A comparative study. *Sensors*, 21(23).
  - [20] Pang, H., Zheng, Z., Zhen, T., & Sharma, A. (2021). Smart farming: An approach for disease detection implementing iot and image processing. *International Journal of Agricultural and Environmental Information Systems*, 12(1), 55–67.
  - [21] Gutiérrez, M., Rafael, P., Sáenz, R., Nicolás, J., Mata, G., Leticia, C., & Vega, R. (2022). INTELIGENCIA ARTIFICIAL EN LA INDUSTRIA ALIMENTARIA. *REVISTA ELECTRONICA*, 44, 225–229.
  - [22] Morozov, O., Tunakova, Y., Hussein, S. M. R. H., Shagidullin, A., Agliullin, T., Kuznetsov, A., Valeev, B., Lipatnikov, K., Anfinogentov, V., & Sakhabutdinov, A. (2022). Addressed Combined Fiber-Optic Sensors as Key Element of Multisensor Greenhouse Gas Monitoring Systems. *Sensors*, 22(13).
  - [23] Medic, T., Ray, P., Han, Y., Broggin, G. A. L., & Kollaart, S. (2024). Remotely sensing inner fruit quality using multispectral LiDAR: Estimating sugar and dry matter content in apples. *Computers and Electronics in Agriculture*, 224.
  - [24] Birrell, S., Hughes, J., Cai, J. Y., & Iida, F. (2020). A field-tested robotic harvesting system for iceberg lettuce. *Journal of Field Robotics*, 37(2), 225–245.
  - [25] Leu, A., Razavi, M., Langstadtler, L., Ristic-Durrant, D., Raffel, H., Schenck, C., Graser, A., & Kuhfuss, B. (2017). Robotic green asparagus selective harvesting. *IEEE/ASME Transactions on Mechatronics*, 22(6), 2401–2410.
  - [26] Montaña-Blacio, M., González-Escarabay, J., Jiménez-Sarango, Ó., Mingo-Morocho, L., & Carrión-Aguirre, C. (2023). Design and deployment of an IoT-based monitoring system for hydroponic crops. *Ingenius*, 2023(30), 9–18.
  - [27] Tongcham, P., Supa, P., Pornwongthong, P., & Prasitmeeboon, P. (2020). Mushroom spawn quality classification with machine learning. *Computers and Electronics in Agriculture*, 179.
  - [28] Yohanes, B., Abraham, M., Bikila, G., Robel, D., Getahun, T., Jale, M., Malesu, A., Tsehaynesh, F., & Lalise, D. (2020). Selection of appropriate substrate for production of oyster mushroom (*Pleurotus ostreatus*). *Journal of Yeast and Fungal Research*, 11(1), 15–25.
  - [29] ILazcano-Bello I., Sandoval-Castro E., Tórner-Campante M., Hernández-Hernández B., Ocampo-Fletes I. & Díaz-Ruiz R., (2021). Evaluación de sustratos, solución nutritiva y enraizador en producción de plántulas de jitomate. *Revista Mexicana de Ciencias Agrícolas* 12(1).
  - [30] Suwannarach, N., Kumla, J., Zhao, Y., & Kakumyan, P. (2022). Impact of Cultivation Substrate and Microbial Community on Improving Mushroom Productivity: A Review. In *Biology* (Vol. 11, Issue 4).
  - [31] Gowda, N., & Alagusundaram, N. A. (2013). Use of thermal imaging to improve the food grains quality during storage. *International Journal of Current Agricultural Research*, 1(7), 34–41.
  - [32] Yaqoob, M., Sharma, S., & Aggarwal, P. (2021). Imaging techniques in Agro-industry and their applications, a review. In *Journal of Food Measurement and Characterization* (Vol. 15, Issue 3, pp. 2329–2343).
  - [33] Aviara, N. A., Liberty, J. T., Olatunbosun, O. S., Shoyombo, H. A., & Oyeniyi, S. K. (2022). Potential application of hyperspectral imaging in food grain quality inspection, evaluation and control during bulk storage. *Journal of Agriculture and Food Research*, 8.
  - [34] An, L., Wang, J., Xiong, N., Wang, Y., You, J., & Li, H. (2022). Assessment of Permeability Windbreak Forests with Different Porosities Based on Laser Scanning and Computational Fluid Dynamics. *Remote Sensing*, 14(14).
  - [35] Abdusalomov, A. B., Islam, B. M. S., Nasimov, R., Mukhiddinov, M., & Whangbo, T. K. (2023). An Improved Forest Fire Detection Method Based on the Detectron2 Model and a Deep Learning Approach. *Sensors*, 23(3).
  - [36] Usha, S., Karthik, M., & Jenifer, R. (2017). Automated Sorting And Grading of Vegetables Using Image Processing. *International Journal of Engineering Research and General Science*, 5(6).
  - [37] Sala, A., Vittone, S., Barrena, R., Sánchez, A., & Artola, A. (2021). Scanning agro-industrial wastes as substrates for fungal biopesticide production: Use of *Beauveria bassiana* and *Trichoderma harzianum* in solid-state fermentation. *Journal of Environmental Management*, 295.
  - [38] Picsek, L., Jeppesen GBIF, T. S., Heilmann-Clausen, J., Laessle, T., & Frøslev, T. (2022). Danish Fungi 2020 - Not Just Another Image Recognition Dataset.
  - [39] Wang, X., Xu, Y., & Wei, X. (2024). Phenotypic characteristics of the mycelium of *Pleurotus geesteranus* using image recognition technology. *Frontiers in Bioengineering and Biotechnology*, 12.
  - [40] Houette, T., Maurer, C., Niewiarowski, R., & Gruber, P. (2022). Growth and Mechanical Characterization of Mycelium-Based Composites towards Future Bioremediation and Food Production in the Material Manufacturing Cycle. *Biomimetics*, 7(3).
  - [41] Angelova, G., Brazkova, M., Stefanova, P., Blazheva, D., Vladov, V., Petkova, N., Slavov, A., Denev, P., Karashanova, D., Zaharieva, R., Enev, A., & Krastanov, A. (2021). Waste rose flower and lavender straw biomass—an innovative lignocellulose feedstock for mycelium biomaterials development using newly isolated *ganoderma resinaceum* galim. *Journal of Fungi*, 7(10).
  - [42] Xia, J., Li, W., Sun, M., & Wang, H. (2022). Application of SERS in the Detection of Fungi, Bacteria and Viruses. In *Nanomaterials* (Vol. 12, Issue 20).
  - [43] Pezzotti, G., Kobara, M., Asai, T., Nakaya, T., Miyamoto, N., Adachi, T., Yamamoto, T., Kanamura, N., Ohgitani, E., Marin, E., Zhu, W., Nishimura, I., Mazda, O., Nakata, T., & Makimura, K. (2021). Raman Imaging of Pathogenic *Candida auris*: Visualization of Structural Characteristics and Machine-Learning Identification. *Frontiers in Microbiology*, 12.
  - [44] Matsumae, H., Sudo, M., Imanishi, T., & Hosoya, T. (2024). Easy-to-set-up image analysis characterizes phenotypic diversity in the growth of mushroom-forming fungus *Schizophyllum commune*.
  - [45] Areesanan, A., Wasilewicz, A., Nicolay, S., Grienke, U., Zimmermann-Klemd, A. M., Rollinger, J. M., & Gründemann, C. (2025). Evaluation of in vitro pharmacological activities of medicinal mushrooms in the context of dry eye disease. *Frontiers in Pharmacology*, 16.
  - [46] Xu, X., Li, J., Zhou, J., Feng, P., Yu, H., & Ma, Y. (2025). Three-Dimensional Reconstruction, Phenotypic Traits Extraction, and Yield Estimation of Shiitake Mushrooms Based on Structure from Motion and Multi-View Stereo. *Agriculture (Switzerland)*, 15(3).
  - [47] de Cianni, R., Varese, G. C., & Mancuso, T. (2023). A Further Step toward Sustainable Development: The Case of the Edible Mushroom Supply Chain. *Foods*, 12(18).
  - [48] Yan, M. Q., Feng, J., Liu, Y. F., Hu, D. M., & Zhang, J. S. (2023). Functional Components from the Liquid Fermentation of Edible and



Medicinal Fungi and Their Food Applications in China. In *Foods* (Vol. 12, Issue 10).

- [49] Sciascia, I., Crosino, A., & Genre, A. (2023). Quantifying root colonization by a symbiotic fungus using automated image segmentation and machine learning approaches. *Scientific Reports*, 13(1).
- [50] Theodosiou, A. A., & Read, R. C. (2023). Artificial intelligence, machine learning and deep learning: Potential resources for the infection clinician. In *Journal of Infection* (Vol. 87, Issue 4, pp. 287–294). W.B. Saunders Ltd.
- [51] Dutta, A., Ramamoorthy, A., Lakshmi, M. G., & Kumar, P. K. (2025). Kolmogorov–Arnold Networks for Automated Diagnosis of Urinary Tract Infections. *Journal of Molecular Pathology*, 6(1), 6.
- [52] Dhanya, V. G., Subeesh, A., Kushwaha, N. L., Vishwakarma, D. K., Nagesh Kumar, T., Ritika, G., & Singh, A. N. (2022). Deep learning based computer vision approaches for smart agricultural applications. In *Artificial Intelligence in Agriculture* (Vol. 6, pp. 211–229). KeAi Communications Co.
- [53] Yuan, Y., Chen, L., Wu, H., & Li, L. (2022). Advanced agricultural disease image recognition technologies: A review. In *Information Processing in Agriculture* (Vol. 9, Issue 1, pp. 48–59). China Agricultural University.
- [54] Jia, J., Hu, F., Zhang, X., Ben, Z., Wang, Y., & Chen, K. (2023). Method of Attention-Based CNN for Weighing *Pleurotus eryngii*. *Agriculture*, 13(9), 1728.
- [55] Lin, J. Y., Tsai, H. L., & Sang, W. C. (2020). Implementation and performance evaluation of integrated wireless multisensor module for aseptic incubator of *Cordyceps militaris*. *Sensors*, 20(15), 4272.
- [56] Supriyono, H., Prakoso, W., & Yahya, N. M. (2024, January). Design and performance testing of automated incubator for Oyster mushroom (*Pleurotus Ostreatus*) cultivation. In *AIP Conference Proceedings* (Vol. 2926, No. 1). AIP Publishing.
- [57] Zheyang, H., Tengis, T., & Batminkh, A. (2020). A study of the incubator model for growing mushrooms. *International Journal of Advanced Culture Technology*, 8(1), 19-25.
- [58] Chong, J. L., Chew, K. W., Peter, A. P., Ting, H. Y., & Show, P. L. (2023). Internet of things (IoT)-Based environmental monitoring and control system for home-based mushroom cultivation. *Biosensors*, 13(1), 98.
- [59] Beć, K. B., Grabska, J., & Huck, C. W. (2022). Miniaturized NIR spectroscopy in food analysis and quality control: Promises, challenges, and perspectives. *Foods*, 11(10), 1465.
- [60] Bwambok, D. K., Siraj, N., Macchi, S., Larm, N. E., Baker, G. A., Pérez, R. L., ... & Fakayode, S. O. (2020). QCM sensor arrays, electroanalytical techniques and NIR spectroscopy coupled to multivariate analysis for quality assessment of food products, raw materials, ingredients and foodborne pathogen detection: Challenges and breakthroughs. *Sensors*, 20(23), 6982.
- [61] Bowler, A., Ozturk, S., di Bari, V., Glover, Z. J., & Watson, N. J. (2023). Machine learning and domain adaptation to monitor yoghurt fermentation using ultrasonic measurements. *Food Control*, 147, 109622.
- [62] Karlsen, S. T., Vesth, T. C., Oregaard, G., Poulsen, V. K., Lund, O., Henderson, G., & Bælum, J. (2021). Machine learning predicts and provides insights into milk acidification rates of *Lactococcus lactis*. *PLoS One*, 16(3), e0246287.
- [63] Wieme, J., Mollazade, K., Malounas, I., Zude-Sasse, M., Zhao, M., Gowen, A., ... & Van Beek, J. (2022). Application of hyperspectral imaging systems and artificial intelligence for quality assessment of fruit, vegetables and mushrooms: A review. *biosystems engineering*, 222, 156-176.
- [64] Tian, H., Wang, T., Liu, Y., Qiao, X., & Li, Y. (2020). Computer vision technology in agricultural automation—A review. *Information processing in agriculture*, 7(1), 1-19.
- [65] Patel, A., Lee, W. S., Peres, N. A., & Fraisse, C. W. (2021). Strawberry plant wetness detection using computer vision and deep learning. *Smart Agricultural Technology*, 1, 100013.
- [66] Yu, J., Zhang, C., Wang, J., Zhang, M., Zhang, X., & Li, X. (2023). Research on asparagus recognition based on deep learning. *IEEE Access*, 11, 117362-117367.
- [67] Bwambok, D. K., Siraj, N., Macchi, S., Larm, N. E., Baker, G. A., Pérez, R. L., ... & Fakayode, S. O. (2020). QCM sensor arrays, electroanalytical techniques and NIR spectroscopy coupled to multivariate analysis for quality assessment of food products, raw materials, ingredients and foodborne pathogen detection: Challenges and breakthroughs. *Sensors*, 20(23), 6982.
- [68] Blasco, J., Aleixos, N., Gómez, J., & Moltó, E. (2007). Citrus sorting by identification of the most common defects using multispectral computer vision. *Journal of Food Engineering*, 83(3), 384-393..