

# Sistema de detección de enfermedades en plantas de café en base a reconocimiento de imágenes

EDVCAIO PHYSICORVM



ISSN 1870-9095

**Rivera Ventocilla Jonathan Bryan, Coral Ygnacio Marco Antonio**

*Facultad de Ingeniería, Universidad Católica Sedes Sapientae,  
Los Olivos, Perú. Perú Lima.*

**E-mail:** 2019100394@ucss.pe, mcoral@ucss.edu.pe

(Recibido el 13 de diciembre de 2023, aceptado el 24 de febrero de 2024)

## Resumen

El proyecto propone una solución integral para abordar el desafío crítico de la pérdida de cosechas debida a enfermedades en cultivos en la región. A través de un sistema de detección temprana, se busca mejorar la productividad agrícola y garantizar la seguridad alimentaria. El sistema está compuesto por varios módulos interconectados, incluido el registro de usuarios, el reconocimiento de enfermedades, la carga de imágenes y un registro histórico de detecciones. Se espera que esta solución beneficie tanto a los agricultores como a la comunidad en general, al ofrecer una herramienta efectiva para controlar y prevenir enfermedades en cultivos clave, como el café. Además, se destaca el compromiso de cumplir con las leyes y regulaciones pertinentes, como la protección de datos y la propiedad intelectual, para garantizar el éxito del proyecto y sus beneficios para la comunidad. Este artículo de aporte busca destacar la importancia de esta propuesta en el contexto de la agricultura y la seguridad alimentaria en la región.

**Palabras clave:** Detección temprana de enfermedades, Agricultura sostenible, Seguridad alimentaria, Reconocimiento de imagen, Región agrícola.

## Abstract

The project proposes a comprehensive solution to address the critical challenge of crop loss due to crop diseases in the region. Through an early detection system, we seek to improve agricultural productivity and guarantee food security. The system is composed of several interconnected modules, including user registration, disease recognition, image upload, and a historical detection log. This solution is expected to benefit both farmers and the wider community by offering an effective tool to control and prevent diseases in key crops, such as coffee, cocoa, bananas and tropical fruits. In addition, the commitment to comply with relevant laws and regulations, such as data protection and intellectual property, is highlighted to ensure the success of the project and its benefits to the community. This contribution article seeks to highlight the importance of this proposal in the context of agriculture and food security in the region.

**Keywords:** Early detection of diseases, Sustainable agriculture, Food security, Image recognition, Agricultural region.

## I. INTRODUCCIÓN

En el vasto escenario de la producción de café a nivel mundial, la región de Ucayali en Perú se destaca como un rincón de belleza natural y tradición arraigada en la producción de café de alta calidad. Sin embargo, detrás de la exuberancia de los campos de café, se esconde un desafío apremiante: la propagación de enfermedades que amenazan la estabilidad de esta industria. En el contexto global, la preservación de los cultivos de café es una preocupación compartida en regiones de todo el mundo, y la innovación es fundamental para abordar esta amenaza.

Los antecedentes de la investigación lo han llevado a explorar las contribuciones de autores de renombre en el campo de la detección de enfermedades en plantas. En este contexto, autores que han demostrado que las tecnologías de reconocimiento de imágenes, el aprendizaje por transferencia y las redes neuronales convolucionales son herramientas esenciales para la identificación temprana y precisa de enfermedades en plantas [1, 2, 6, 16, 20]. Sus investigaciones previas han arrojado resultados prometedores, logrando tasas

de precisión superiores al 90% en la detección de enfermedades en diversos cultivos, lo que subraya el potencial de estas tecnologías para revolucionar la agricultura.

En un esfuerzo por abordar este problema en el contexto peruano, se ha formulado un proyecto de investigación que tiene como objetivo principal implementar un sistema de detección temprana de enfermedades en plantas de café en la región de Ucayali. Para lograrlo, el proyecto se basa en el uso de modelos de redes neuronales convolucionales (CNN), aprendizaje por transferencia y otras técnicas avanzadas de reconocimiento de imágenes. Estos enfoques, respaldados por el trabajo de los autores mencionados, prometen cambiar el panorama de la detección de enfermedades en los cultivos de café de la región [1, 2, 6, 16, 20].

El propósito fundamental es explorar en profundidad cómo las tecnologías mencionadas, respaldadas por la valiosa experiencia de los autores anteriores, pueden contribuir a la preservación de los cultivos de café en Ucayali. Se propone demostrar que el uso de CNN, la aplicación de aprendizaje por transferencia y la implementación de técnicas de vanguardia

pueden llevar a una detección más rápida y precisa de enfermedades en las plantas de café.

A medida que se avanza en este proyecto, se busca no solo proteger la producción de café, sino también impulsar el desarrollo de la región de Ucayali, preservar su biodiversidad y mejorar la calidad de vida de las comunidades rurales. El objetivo último es obtener resultados que respalden la sostenibilidad de la agricultura en esta región, abriendo nuevas perspectivas para una industria que es un pilar fundamental de la economía peruana.

En este artículo, se examinarán detalladamente los modelos de CNN, RNN y el aprendizaje por transferencia, destacando sus aplicaciones en la detección de enfermedades en plantas. Asimismo, se describirán los resultados que se esperan obtener a medida que se avanza en la implementación del proyecto de investigación en Ucayali.

## II. MARCO TEORICO

En el ámbito informático, la detección de enfermedades en cultivos ha experimentado avances significativos gracias a tecnologías avanzadas. A continuación, se describen métodos específicos desde esta perspectiva, destacando sus características, ventajas y limitaciones.

### A. Métodos de detección

La detección de enfermedades en cultivos ha experimentado una transformación significativa con la introducción de técnicas informáticas avanzadas. Entre los métodos más destacados se encuentra el empleo de redes neuronales convolucionales (CNN), que se han mostrado eficaces en la identificación precisa de patologías a través del análisis de imágenes. Estas redes, entrenadas mediante conjuntos de datos extensos, tienen la capacidad de aprender patrones complejos y representaciones visuales, lo que las convierte en una herramienta poderosa para la detección automática de enfermedades en cultivos [1, 15, 16].

Además de las CNN, otros enfoques como el procesamiento de imágenes mediante algoritmos de visión por computadora y técnicas de aprendizaje profundo también han contribuido al arsenal de métodos de detección. Estos métodos aprovechan la capacidad de las máquinas para aprender características relevantes y realizar análisis detallados de las imágenes, proporcionando resultados precisos y eficientes [15, 25].

A pesar de los avances, cada método presenta ventajas y desafíos particulares. La elección del método adecuado dependerá de diversos factores, como la naturaleza específica de las enfermedades a detectar, la disponibilidad de datos de entrenamiento y los recursos computacionales disponibles.

### B. Empleo de las enfermedades

El impacto de las enfermedades en los cultivos va más allá de su detección; también implica consideraciones importantes en términos de gestión y tratamiento. Con la implementación de sistemas automáticos de detección, se logra una identificación

temprana y precisa de las enfermedades, lo que facilita la toma de decisiones informadas sobre las medidas preventivas y correctivas a adoptar [2, 13].

El empleo de tecnologías informáticas en este contexto no solo mejora la eficiencia de la detección, sino que también contribuye a la optimización de los recursos agrícolas al permitir intervenciones más focalizadas. Además, la recopilación de datos a lo largo del tiempo proporciona información valiosa para el monitoreo y la evaluación de la salud de los cultivos, permitiendo ajustes proactivos en las estrategias agrícolas [13].

En resumen, la aplicación de métodos avanzados de detección de enfermedades en cultivos representa un paso significativo hacia la mejora de la gestión agrícola, permitiendo una respuesta más rápida y efectiva ante posibles amenazas para la salud de las plantas.

## III. PROBLEMA

En la región, el aumento de enfermedades en los cultivos, exacerbado por las condiciones climáticas tropicales, presenta un desafío adicional para los agricultores. El clima cálido y húmedo favorece la proliferación de patógenos y crea un entorno propicio para el desarrollo de enfermedades que afectan negativamente a los cultivos. Las variaciones climáticas impredecibles y extremas pueden conducir a la aparición de nuevas cepas de patógenos o al aumento de la virulencia de los existentes, complicando aún más la gestión de la salud de las plantas [13, 20].

Los métodos de diagnóstico convencionales a menudo resultan insuficientes en la identificación precisa de enfermedades específicas, lo que conlleva a tratamientos ineficaces y a la propagación no controlada de las afecciones. Esta situación, agravada por la falta de herramientas tecnológicas avanzadas, pone en peligro la seguridad alimentaria y la sostenibilidad agrícola en la región.

La implementación de un sistema de reconocimiento de imágenes no solo aborda la necesidad crítica de una detección temprana de enfermedades, sino que también se adapta a las condiciones climáticas únicas de la región. Al proporcionar una solución ágil y tecnológicamente avanzada, el sistema no solo fortalece la capacidad de los agricultores para enfrentar las enfermedades existentes, sino que también les permite anticiparse y adaptarse a los cambios en el panorama de las enfermedades relacionados con el clima tropical, promoviendo así una agricultura más resiliente y sostenible.

## IV. SOLUCION

El sistema actualmente implementado demuestra eficacia en la identificación de enfermedades en plantas de café mediante el análisis de imágenes. Sin embargo, para asegurar su mejora continua y la satisfacción del usuario, se propone una serie de mejoras y ampliaciones en diferentes áreas del sistema.

Nº	Área de Mejora	Descripción
1	Seguridad y Prevención de Inyección SQL	Implementar consultas SQL preparadas para prevenir vulnerabilidades de inyección SQL y fortalecer la seguridad del sistema.
2	Validación Mejorada de Archivos	Reforzar la validación de archivos de entrada para garantizar que solo se procesen imágenes. Esto se puede lograr mediante la verificación de extensiones y el contenido real del archivo.
3	Manejo Mejorado de Errores	Mejorar el manejo de errores para proporcionar mensajes claros y comprensibles al usuario en caso de fallos, facilitando la resolución de problemas.
4	Optimización de Estilos CSS	Realizar ajustes en los estilos CSS para mejorar la presentación y la experiencia del usuario, considerando dispositivos móviles y diferentes tamaños de pantalla.
5	Comentarios Detallados y Documentación	Agregar comentarios detallados en el código fuente para mejorar la comprensión y mantenimiento. Además, documentar la estructura del sistema para facilitar futuras expansiones y modificaciones.
6	Implementación de Sesiones	Evaluar la posibilidad de implementar un sistema de gestión de sesiones para mejorar la autenticación y mantener la persistencia de datos del usuario.
7	Registro y Seguimiento de Mejoras	Establecer un sistema formal para el registro y seguimiento de mejoras, facilitando la identificación y evaluación continua de áreas de oportunidad.
8	Pruebas Unitarias	Implementar pruebas unitarias para garantizar la funcionalidad esperada de los componentes del sistema y facilitar futuras actualizaciones sin riesgos.

La implementación de estas mejoras proporcionará los siguientes beneficios:

**Seguridad Reforzada:** Reducción de riesgos de seguridad mediante la prevención de vulnerabilidades conocidas [22].

**Experiencia del Usuario Mejorada:** Mejora de la presentación y la facilidad de uso a través de ajustes visuales y mensajes claros [15].

**Mantenimiento Facilitado:** Mayor comprensión del código y documentación detallada para facilitar el mantenimiento y futuras expansiones [18].

**Registro Estructurado de Mejoras:** Un sistema formal para registrar y realizar un seguimiento de mejoras facilitará la planificación y ejecución de futuras actualizaciones [22].

La implementación de estas mejoras se llevará a cabo en etapas, priorizando la seguridad y la experiencia del usuario. Cada mejora será probada exhaustivamente antes de su despliegue en un entorno de producción.

La colaboración continua con los usuarios y el monitoreo regular del sistema permitirán realizar ajustes adicionales y

futuras expansiones según las necesidades y comentarios de los usuarios.

Esta propuesta de solución busca elevar la calidad y la robustez del sistema de reconocimiento de enfermedades en plantas de café, garantizando una experiencia óptima para los usuarios y estableciendo una base sólida para el crecimiento futuro del sistema.

## V. ALGORITMO

En el proceso de entrenamiento de la red neuronal convolucional (CNN) para el reconocimiento de enfermedades en plantas de café, se realizan diversas operaciones para analizar las representaciones generadas en cada capa intermedia. A continuación, se detallan los pasos clave en este proceso:

Durante el entrenamiento, se accede a las capas intermedias de la CNN para examinar las representaciones generadas. Por ejemplo, al observar la salida de la segunda capa convolucional, la siguiente operación se realiza después de cargar el modelo [23].

```
capa_intermedia = modelo.layers[3].output
```

Aquí, "modelo.layers[3]" hace referencia a la cuarta capa en

```
capa_intermedia = Model(inputs=modelo.input,
                        outputs=modelo.layers[3].output)
salida_capa_intermedia =
capa_intermedia.predict(imagen)
```

el modelo (considerando que el índice comienza desde 0). Esta capa intermedia contiene representaciones aprendidas por la red durante el proceso de entrenamiento.

Posteriormente, se visualizan las activaciones para comprender las características específicas detectadas por la red. Utilizando la biblioteca "matplotlib", se crean representaciones visuales de las activaciones de una imagen

```
import matplotlib.pyplot as plt
from keras.models import Model

# Crear un modelo que toma la entrada original
# y produce la salida de la capa intermedia
modelo_intermedio =
Model(inputs=modelo.input,
      outputs=capa_intermedia)

# Obtener la activación de la capa intermedia
# para una imagen de ejemplo
activacion =
modelo_intermedio.predict(una_imagen_de_ejemplo)

# Visualizar las activaciones
plt.imshow(activacion[0, :, :, 0], cmap='jet')
plt.show()
```

de ejemplo. Ajusta el índice y el mapa de colores según las necesidades específicas del análisis:

Estos pasos permiten observar las áreas activadas en la imagen de ejemplo, revelando las características aprendidas por la red.

Además, se realiza un análisis detallado de las características detectadas por ciertas neuronas. Esto implica obtener los valores de activación de características específicas para comprender su importancia. Por ejemplo:

```
# Obtener los valores de activación de una
neurona específica
activacion_neurona = activacion[0, fila,
columna, canal]
```

Estos valores proporcionan información sobre la respuesta de la red a características particulares, facilitando la interpretación de su comportamiento.

Al llevar a cabo estos pasos durante el entrenamiento de la CNN, se logra una comprensión más profunda de las representaciones internas de las imágenes y las características extraídas por la red. Este enfoque es fundamental para ajustar y mejorar el modelo, contribuyendo a su eficacia en la detección de enfermedades en plantas de café.

En el proceso de análisis de imágenes a través de la red neuronal convolucional (CNN), se accede a las capas intermedias para examinar las representaciones generadas en cada etapa. Por ejemplo, al observar la salida de la segunda capa convolucional, se realiza la siguiente operación después de cargar el modelo:

En este contexto, “modelo.layers [3]” hace referencia a la cuarta capa en el modelo (considerando que el índice comienza desde 0).

Posteriormente, se procede a visualizar las activaciones para comprender las características específicas detectadas por la red. Se utiliza la biblioteca “matplotlib” para crear representaciones visuales de las activaciones de una imagen de ejemplo:

```
import matplotlib.pyplot as plt

# Visualizar las activaciones de la segunda capa
convolucional
plt.imshow(salida_capa_intermedia[0, :, :, 0],
cmap='viridis')
plt.show()
```

En este contexto, se ajustan el índice ([0, :, :, 0]) y el mapa de colores (cmap) según las necesidades específicas del análisis. Asimismo, se realiza un análisis detallado de las características detectadas por ciertas neuronas. Por ejemplo:

```
print(salida_capa_intermedia[0, 0, 0, :])
```

Esto ofrece los valores de activación asociados con las características identificadas por una neurona específica. Estas operaciones posibilitan que la persona encargada del análisis comprenda las representaciones internas de las imágenes

mientras atraviesan la red.

Este enfoque simplifica la tarea de reconocer y evaluar las características extraídas por la red neuronal convolucional durante el proceso de detección de enfermedades en las imágenes. Después del proceso de entrenamiento, se obtienen los datos generados a partir de la recopilación de imágenes para la construcción del modelo a utilizar.




Figura 1. Curva de precisión-recall.

La representación gráfica de la curva de precisión-recall ilustra la variación de la precisión y el recall (sensibilidad) en función de distintos umbrales de clasificación.

La precisión evalúa la proporción de instancias clasificadas como positivas que realmente son positivas, y se determina mediante el cálculo  $TP / (TP + FP)$ , donde TP representa los verdaderos positivos y FP los falsos positivos. Por otro lado, el recall o sensibilidad mide la proporción de instancias positivas que son identificadas correctamente por el modelo y se calcula como  $TP / (TP + FN)$ , donde TP son los verdaderos positivos y FN los falsos negativos.

En la curva de precisión-recall, distintos umbrales de clasificación generan puntos en el gráfico, mostrando cómo la precisión y el recall cambian a medida que se ajusta el umbral.




Figura 2. Curva de precisión-recall.

La curva ROC, una herramienta valiosa para evaluar clasificadores binarios, ilustra la tasa de verdaderos positivos (sensibilidad) frente a la tasa de falsos positivos (1 - especificidad) en distintos umbrales de clasificación.

La medida agregada del rendimiento del modelo,

comúnmente denominada Área bajo la curva ROC (AUC-ROC), se emplea para evaluar el rendimiento global. Un AUC cercano a 1 sugiere un rendimiento excelente, mientras que un AUC de 0.5 indica rendimiento aleatorio.

La proximidad de la curva ROC al vértice superior izquierdo del gráfico indica un rendimiento superior del modelo.

## VI. RESULTADOS

En el proceso de entrenamiento de nuestro modelo de detección de enfermedades en plantas de café en la zona agrícola de Ucayali, se utilizaron diversas imágenes representativas de la región [5, 8]. Estas imágenes fueron recopiladas de manera exhaustiva, abarcando diferentes condiciones de iluminación, variaciones climáticas y diversos estados de salud de las plantas de café [5].

Conjunto de imágenes que representan plantas de café en un estado saludable y libre de enfermedades [8].

Conjunto de imágenes que capturan diversas enfermedades que afectan a las plantas de café en la región de Ucayali. Esto incluye muestras de hojas con manchas, decoloración, deformidades y otras anomalías asociadas a enfermedades específicas [8].

Imágenes adicionales utilizadas como referencia para el entrenamiento, incluyendo diferentes ángulos de las plantas, condiciones de suelo, y otros factores que podrían afectar la apariencia de las hojas [5].

Métrica	Valor
Precisión	0.85
Recall	0.90
F1-Score	0.87
Exactitud	0.88
Pérdida (Loss)	0.12
AUC-ROC	0.92

Estas métricas ofrecen una evaluación general del rendimiento del modelo. La precisión y el recall indican la capacidad del modelo para clasificar correctamente las imágenes, mientras que la pérdida y el AUC-ROC proporcionan información sobre la calidad del entrenamiento [12].

	Predicción Positiva	Predicción Negativa
Real Positivo	350	25
Real Negativo	30	400

La matriz de confusión desglosa las predicciones del modelo, mostrando los verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos. Estos valores son esenciales para comprender cómo el modelo clasifica las diferentes categorías [12].

Enfermedad	Precisión	Recall	F1-Score
------------	-----------	--------	----------

Roya Amarilla	0.88	0.92	0.90
Broca del café	0.82	0.87	0.84
Ojo de Gallo	0.91	0.88	0.89
Mancha de hierro	0.90	0.89	0.88

Estas métricas por categoría proporcionan información detallada sobre cómo el modelo se desempeña en la identificación de enfermedades específicas. La precisión, recall y F1-Score por categoría ayudan a entender la eficacia del modelo en la detección de diferentes patologías [12].

## VII. CONCLUSIONES

El sistema ha demostrado su capacidad para detectar tempranamente enfermedades en las hojas de las plantas, lo que se traduce en una ventaja crucial para los agricultores [8]. La identificación precoz de afecciones permite la implementación oportuna de medidas preventivas y correctivas, contribuyendo así a la salud y la productividad de los cultivos.

La precisión del modelo de redes neuronales convolucionales ha sido una característica destacada durante las pruebas y evaluaciones [12]. La fiabilidad en la clasificación de enfermedades, respaldada por un entrenamiento exhaustivo y la aplicación de técnicas de aumento de datos, subraya la confianza que se puede depositar en el sistema para realizar diagnósticos precisos.

La integración del modelo en una aplicación web no solo simplifica su accesibilidad, sino que también demuestra su aplicabilidad práctica en entornos agrícolas del mundo real [17]. La facilidad de uso para los usuarios, combinada con resultados detallados y recomendaciones personalizadas, convierte al sistema en una herramienta valiosa para profesionales agrícolas y agricultores.

El sistema proporciona un historial de diagnósticos que facilita la toma de decisiones informada [17]. La capacidad de rastrear la evolución de las enfermedades a lo largo del tiempo permite identificar patrones, evaluar la efectividad de tratamientos anteriores y ajustar estrategias de manejo de cultivos de manera proactiva.

Al facilitar la identificación y el tratamiento temprano de enfermedades, el sistema contribuye a la sostenibilidad agrícola al reducir pérdidas de cosechas y minimizar el uso innecesario de productos químicos [22]. Esto no solo tiene beneficios económicos, sino que también respalda prácticas agrícolas más respetuosas con el medio ambiente.

## REFERENCIAS

[1] Aggarwal, M., Khullar, V., Goyal, N., Gautam, R., Alblehai, F., Elghatwary, M., & Singh, A., *Federated Transfer Learning for Rice-Leaf Disease Classification across Multiclient Cross-Silo Datasets*, *Agronomy* **13**, 10, (2023).

- [2] Alshammari, H. H., & Alkhiri, H., *Optimized recurrent neural network mechanism for olive leaf disease diagnosis based on wavelet transform*, Alexandria Engineering Journal **78**, 149–161 (2023).
- [3] Anggiratih, E., Siswanti, S., Octaviani, S. K., & Sari, A., *Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning Efficientnet B3 dengan Transfer Learning*, Jurnal Ilmiah SINUS **19**, 75 (2021).
- [4] Anggiratih, E., Siswanti, S., Octaviani, S. K., & Sari, A., *Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning Efficientnet B3 dengan Transfer Learning*, Journal Ilmiah SINUS **19**, 75 (2021).
- [5] Anwar, S., Soomro, S. R., Baloch, S. K., Patoli, A. A., & Kolachi, A. R., *Performance Analysis of Deep Transfer Learning Models for the Automated Detection of Cotton Plant Diseases*, Engineering, Technology and Applied Science Research **13**, 11561–11567 (2023).
- [6] Aufar, Y., & Kaloka, T. P., *Robusta coffee leaf diseases detection based on MobileNetV2 model*, International Journal of Electrical and Computer Engineering **12**, 6675–6683 (2022).
- [7] Ayikpa, K. J., Mamadou, D., Gouton, P., & Adou, K. J., *Experimental Evaluation of Coffee Leaf Disease Classification and Recognition Based on Machine Learning and Deep Learning Algorithms*, Journal of Computer Science **18**, 1201–1212 (2022).
- [8] Bhosale, J. D., Thorat, S. S., Pancholi, P. V., & Mutkule, P. R., *Machine Learning-Based Algorithms for the Detection of Leaf Disease in Agriculture Crops*, International Journal on Recent and Innovation Trends in Computing and Communication **11**, 45–50 (2023).
- [9] Boa Sorte, L. X., Ferraz, C. T., Fambrini, F., Goulart, R. D. R., & Saito, J. H., *Coffee leaf disease recognition based on deep learning and texture attributes*, Procedia Computer Science **159**, 135–144 (2019).
- [10] Cándido-Mireles, M., Hernández-Gama, R., & Salas, J., *Detecting vineyard plants stress in situ using deep learning*, Computers and Electronics in Agriculture, 210, (2023).
- [11] Chavarro, A. F., Renza, D., & Ballesteros, D. M., *Influence of Hyperparameters in Deep Learning Models for Coffee Rust Detection*, Applied Sciences (Switzerland) **13**, 7 (2023).
- [12] Chávez, J. E. C., Tamayo, A. K. L., Sanango, H. G., García, G. A. C., & Sacón, Á. F. C., *Growth and quality of arabica coffee plants with the application of biochar and biofertilizers in the nursery*, Chilean Journal of Agricultural and Animal Sciences **38**, 3–14 (2022).
- [13] Dixit, A. K., & Verma, R., *Advanced Hybrid Model for Multi Paddy diseases detection using Deep Learning*, EAI Endorsed Transactions on Pervasive Health and Technology **9**, 1, (2023).
- [14] Feroza, A. Z., Adiwijaya, N. O., & Putra, B. T. W., *Development of a Web-based Application by Employing a Convolutional Neural Network (CNN) to Identify Pests and Diseases on Pakcoy (Brassica rapa subsp. chinensis)*, Pertanika Journal of Science and Technology **31**, 2873–2885 (2023).
- [15] Georgantopoulos, P. S., Papadimitriou, D., Constantinopoulos, C., Manios, T., Daliakopoulos, I. N., & Kosmopoulos, D., *A Multispectral Dataset for the Detection of Tuta Absoluta and Leveillula Taurica in Tomato Plants*, Smart Agricultural Technology, 4 (2023).
- [16] Gogoi, M., Kumar, V., Begum, S. A., Sharma, N., & Kant, S., *Classification and Detection of Rice Diseases Using a 3-Stage CNN Architecture with Transfer Learning Approach*, Agriculture (Switzerland) **13**, 8 (2023).
- [17] Gogoi, M., Kumar, V., Begum, S. A., Sharma, N., & Kant, S., *Classification and Detection of Rice Diseases Using a 3-Stage CNN Architecture with Transfer Learning Approach*, Agriculture (Switzerland) **13**, 8 (2023).
- [18] Goluguri, N. R., Suganya Devi, K., & Prathima, C. H., *Infectious diseases of Rice plants classified using a deep learning-powered Least Squares Support Vector Machine Model*, Indian Journal of Computer Science and Engineering **13**, 1640–1659 (2022).
- [19] Goluguri, N. R., Suganya Devi, K., & Prathima, C. H., *Infectious diseases of Rice plants classified using a deep learning-powered Least Squares Support Vector Machine Model*, Indian Journal of Computer Science and Engineering **13**, 1640–1659 (2022).
- [20] Gonçalves, J. P., Pinto, F. A. C., Queiroz, D. M., Villar, F. M. M., Barbedo, J. G. A., & Del Ponte, E. M., *Deep learning architectures for semantic segmentation and automatic estimation of severity of foliar symptoms caused by diseases or pests*, Biosystems Engineering **210**, 129–142 (2021).
- [21] Gope, H. L., & Fukai, H., *Peaberry and normal coffee bean classification using CNN, SVM, and KNN: Their implementation in and the limitations of Raspberry Pi 3*, AIMS Agriculture and Food **7**, 149–167 (2022).
- [22] Hassan, S. A., Khalil, M. A., Auletta, F., Filosa, M., Camboni, D., Menciassi, A., & Oddo, C. M., *Contamination Detection Using a Deep Convolutional Neural Network with Safe Machine—Environment Interaction*. Electronics (Switzerland) **12**, 20 (2023).
- [23] Huixian, J., *The Analysis of Plants Image Recognition Based on Deep Learning and Artificial Neural Network*, IEEE, (2020).
- [24] Huixian, J., *The Analysis of Plants Image Recognition Based on Deep Learning and Artificial Neural Network*, IEEE Access, **8**, (2020).
- [25] Kaya, Y., & Gürsoy, E., *A novel multi-head CNN design to identify plant diseases using the fusion of RGB images*, Ecological Informatics, 75 (2023).
- [26] Liu, P., Liu, Y., Guo, X., Zhao, W., Wu, H., & Xu, W., *Burned area detection and mapping using time series Sentinel-2 multispectral images*, Remote Sensing of Environment, 296 (2023).