



Ciencia Latina Revista Científica Multidisciplinar, Ciudad de México, México.
ISSN 2707-2207 / ISSN 2707-2215 (en línea), enero-febrero 2025,
Volumen 9, Número 1.

https://doi.org/10.37811/cl_rcm.v9i1

Uso de U-Net Y Redes Neuronales Convolucionales para la Detección de la Moniliasis (*Moniliophthora Roreri*) en Mazorcas De Cacao

**RADIO-HISTOPATHOLOGICAL CORRELATION IN PATIENTS
WITH NODULES SUSPICIOUS OF BREAST CANCER IN
IMAGING CLINIC, PERIOD 2021-2023**

Héctor Suárez Díaz

Universidad Juarez Autónoma De Tabasco

Ángel Niño de Rivera Hermosillo

Universidad Juarez Autónoma De Tabasco

Jorge Armín Aguilar Camelo

Universidad Juarez Autónoma De Tabasco

Marco Aurelio González Romo

Universidad Juarez Autónoma De Tabasco

Maria Magdalena Leue Luna

Universidad Juarez Autónoma De Tabasco

Uso de U-Net Y Redes Neuronales Convolucionales para la Detección de la Moniliasis (*Moniliophthora Roreri*) en Mazorcas De Cacao

Arcely Aquino Ruíz¹

<https://orcid.org/0009-0009-7363-9992>

arcely.ar@villahermosa.tecnm.mx

Tecnológico Nacional de México Campus Villahermosa

Raymundo García Mínguez

<https://orcid.org/0009-0005-4615-6654>

raymundo.gm@villahermosa.tecnm.mx

Tecnológico Nacional de México

José Ney Garrido Vázquez

<https://orcid.org/0000-0003-3905-0120>

jose.gv@villahermosa.tecnm.mx

Tecnológico Nacional de México Campus Villahermosa

Dulce María León De la O

<https://orcid.org/0000-0003-0877-7861>

dulce.leono@villahermosa.tecnm.mx

Tecnológico Nacional de México Campus Villahermosa

Carlos Raúl Muñoz Rodríguez

<https://orcid.org/0009-0001-7329-3014>

carlos.mr@villahermosa.tecnm.mx

Tecnológico Nacional de México

Carlos Armando Arellano Cruz

121300032@villahermosa.tecnm.mx

Instituto Tecnológico de Villahermosa, correo

RESUMEN

El presente trabajo aborda la problemática en el sector agrícola; la disminución de la producción del cacao a causa de la enfermedad de la moniliasis (*Moniliophthora roreri*) enfermedad que provoca pérdidas de hasta el 90% en los cacaotales y que como alternativa se desarrolla **KĀKĀWOL** (*Cacaotales en lengua chontal*), una *app* móvil para Android que utiliza inteligencia artificial (IA) con modelos U-net y redes neuronales convolucionales (CNN) que responde a la complejidad única de la detección de moniliasis en mazorcas de cacao, que a diferencia de los modelos de clasificación tradicionales, que solo detectan la presencia o ausencia de la enfermedad, U-net ofrece una segmentación semántica precisa, crucial para identificar las diferentes etapas de la moniliasis en una misma imagen. Las Redes neuronales convolucionales estándar no logran una segmentación tan precisa de las etapas. U-net permite una representación visual y cuantitativa del avance de la moniliasis y destaca por su capacidad para distinguir y etiquetar píxeles pertenecientes a diferentes clases en una imagen, lo que permite identificar simultáneamente: Puntos negros iniciales, Manchas grandes de desarrollo, Manifestación del hongo blanco superficial. El uso de U-net en este contexto destaca por su capacidad de ofrecer un análisis más profundo y detallado. Sin embargo, se resalta que el aprovechamiento de estas tecnologías aún es limitado en algunos sectores económicos del país, subrayando la necesidad de ampliar su implementación para potenciar el desarrollo agrícola.

Palabras clave: segmentación semántica, u-net, aprendizaje profundo, redes neuronales convolucionales, moniliasis.

¹ Autor principal

Correspondencia: arcely.ar@villahermosa.tecnm.mx

Use of U-Net And Convolutional Neural Networks for the Detection of Moniliasis (*Moniliophthora Roreri*) in Cocoa Beans

ABSTRACT

This work addresses the problem in the agricultural sector; the decrease in cocoa production due to the moniliasis disease (*Moniliophthora roreri*), a disease that causes losses of up to 90% in cocoa plantations and which, as an alternative, is developing KÄKÄWOL (Cacaotales in Chontal language), a mobile app for Android that uses artificial intelligence (AI) with U-net models and convolutional neural networks (CNN) that responds to the unique complexity of moniliasis detection, unlike traditional classification models, which only detect the presence or absence of the disease, U-net offers precise semantic segmentation, crucial to identify the different stages of moniliasis in the same image. Standard Convolutional Neural Networks do not achieve such precise segmentation of stages. U-net allows a visual and quantitative representation of the progression of moniliasis and stands out for its ability to distinguish and label pixels belonging to different classes in an image, allowing simultaneous identification: Initial black spots. Large development spots, Manifestation of superficial white fungus. The use of U-net in this context stands out for its ability to offer a deeper and more detailed analysis. However, it is highlighted that the use of these technologies is still limited in some economic sectors of the country, highlighting the need to expand their implementation to enhance agricultural development.

Keywords: semantic segmentation, u-net, deep learning, convolutional neural networks, moniliasis

Artículo recibido 05 enero 2025

Aceptado para publicación: 15 febrero 2025



INTRODUCCIÓN

El cambio climático ha provocado una crisis importante en la producción del cacao a nivel mundial, aunado a que se han propagado enfermedades, las prácticas agrícolas no efectivas en el control y manejo de estas, no ayudan a erradicarlas, una amenaza que afecta hasta el 90% de la producción de cacao es el hongo de la moniliasis (*Moniliophthora roreri*).

En los Estados mexicanos de Veracruz, Guerrero, Chiapas y particularmente Tabasco, que aporta más del 60% de la producción nacional, este hongo ha estado impactando la estabilidad económica de más de 31,000 familias dependientes de este cultivo. En México, actualmente existen aproximadamente 45,000 productores de cacao, quienes han enfrentado grandes desafíos en las últimas décadas. En 1987 el país alcanzó una cifra histórica de 59,000 toneladas, posicionándose como el octavo productor a nivel mundial. Sin embargo, a partir de la aparición de la moniliasis en la década de los 2000, la producción disminuyó en un 43.2% representando pérdidas económicas, aumentando el desempleo y pobreza. La producción actual alcanza apenas 28,000 Toneladas de cacao.

En los últimos años, el avance en tecnologías de inteligencia artificial (IA) ha permitido el desarrollo de diversas aplicaciones para la detección de enfermedades en cultivos. A diferencia de otros países productores que avanzaron adoptando tecnologías agrícolas innovadoras y estrategias efectivas contra plagas y enfermedades, México quedó rezagado en el desarrollo de su industria cacaotera. Es por ello por lo que con la app móvil KÄKÄWOL se busca ser una herramienta tecnológica que coadyuve en las problemáticas que se afronta actualmente:

- Envejecimiento del 25% de los cacaotales en Tabasco, con más de 40 años.
- Falta de control de plagas y enfermedades.
- Prácticas agrícolas no sustentables.
- Ausencia de herramientas tecnológicas en el sector agrícola.
- Falta de comunicación entre agricultores y dependencias gubernamentales del sector agropecuario.
- Falta de difusión eficiente de los programas de apoyo.
- Desconocimiento de los riesgos y manejo de la moniliasis, sin tratamiento definitivo.

Ante la crisis global de desabasto de cacao, **KÄKÄWOL** puede contribuir a estabilizar la producción para satisfacer la creciente demanda, impactando positivamente los **ejes transversales** de:



- **Impacto social:** Mejorar la calidad de vida y estabilidad financiera de los productores del cacao al ofrecer un sistema de diagnóstico rápido y preciso que permite combatir la moniliasis. Esto ayuda a proteger los ingresos de las familias agrícolas y fortalecer la seguridad alimentaria.
- **Sustentabilidad y sostenibilidad:** KÄKÄWOL fomenta prácticas de manejo ecológico al ofrecer tratamientos orgánicos, contribuyendo a proteger la salud de los agricultores y preservando un recurso de vital importancia histórica y cultural, presente en la dieta diaria del sureste mexicano.
- **Tecnologías disruptivas de la Industria 4.0:** El uso de inteligencia artificial para el análisis de imágenes y la detección temprana de la moniliasis.

Con este último eje, las oportunidades de crecimiento de **KÄKÄWOL** abarcan su capacidad de expansión global y de adaptación a otros cultivos afectados por diversas plagas y enfermedades. Su incursión en el ámbito de la *agricultura inteligente* radica en el uso de *inteligencia artificial y análisis de datos*, ya que con el *uso de U-Net*, la *segmentación semántica* es una tarea fundamental en el campo de la visión por computadora y tiene el objetivo de clasificar cada píxel de una imagen en categorías claras.

Desde su creación, U-Net ha sido adaptado a varios campos, que incluyen la detección remota, la agronomía y la segmentación de imágenes clínicas, y ha demostrado su capacidad para abordar problemas desafiantes con un conjunto de datos limitados. Las variaciones actuales, incluyendo la *Attention U-Net*, *U-Net* y *Sharp U-Net*, han mejorado aspectos como el flujo de gradientes, la atención a las regiones relevantes y la precisión en bordes, entre otros, que extienden sus capacidades (Zhou et al., 2018; Oktay et al., 2018).

Justificación

Los modelos de clasificación tradicionales solo pueden determinar la presencia o ausencia de la enfermedad y las Redes neuronales convolucionales estándar no logran una segmentación tan precisa de las etapas. U-net permite una representación visual y cuantitativa del avance de la moniliasis.

¿Por qué el uso de U-net?

- Alta precisión en segmentación de imágenes médicas y biológicas
- Capacidad de manejar datasets pequeños con entrenamiento efectivo
- Arquitectura que permite identificar características sutiles
- Adaptabilidad para reconocer patrones en diferentes etapas de una enfermedad



La arquitectura U-Net ha transformado de manera revolucionaria la segmentación semántica en imágenes al brindar resultados precisos y eficientes. Esta arquitectura ha demostrado ser particularmente efectiva en aplicaciones biomédicas donde los datos anotados son limitados, y en consecuencia ha demostrado ser influyente generando una amplia adopción e inspirando en última instancia el desarrollo de variantes que introducen correcciones a deficiencias importantes del modelo original, incluida la necesidad de datos anotados a gran escala y la generalización a nuevos dominios (Ronneberger et al., 2015).

MATERIAL Y MÉTODOS

La muestra utilizada se compone de un conjunto de imágenes de mazorcas de cacao tomadas en campo, las cuales presentan distintas etapas de la enfermedad de la moniliasis. Estas imágenes provienen de plantaciones reales, donde cada fotografía fue anotada para identificar de forma precisa las áreas afectadas, indicando si la mazorca presentaba las primeras manchas negras, las lesiones avanzadas más extensas o la presencia de hongo blanquecino en la superficie. Se recopilieron 500 imágenes para reflejar la variabilidad de condiciones ambientales, estados de maduración del cacao y severidad de la enfermedad, asegurando así la representatividad necesaria para el entrenamiento y evaluación del modelo.

Dado que el objetivo principal del proyecto fue implementar un modelo de segmentación semántica basado en U-Net con redes neuronales convolucionales, el análisis se centró en métricas específicas de validación de modelos de visión por computadora.

Para cada una de las fases de la enfermedad (etapa inicial con puntos negros, etapa intermedia con manchas más amplias y etapa avanzada con hongo visible), se utilizaron las siguientes métricas calculadas a partir de la matriz de confusión:

- Exactitud (Accuracy)
- Precisión (Precision)
- Sensibilidad (Recall)
- F1-Score, complementadas con la revisión de las matrices de confusión.

Estas métricas permiten evaluar la calidad de la segmentación comparando las áreas detectadas por el modelo con las etiquetas verdaderas. Por ejemplo, la precisión mide qué tan bien el modelo evita falsos positivos, mientras que el *recall* indica su capacidad de detectar correctamente las verdaderas áreas afectadas. El *F1-Score* equilibra estos dos aspectos, ofreciendo una métrica global de rendimiento.



La implementación de una arquitectura U-Net para segmentar distintas fases de la moniliasis en una misma imagen de cacao resulta relativamente novedosa en el ámbito agrícola. La decisión de emplear esta metodología se basó en la capacidad de U-Net para manejar segmentaciones multiclase con alta precisión, incluso con conjuntos de datos moderadamente limitados. Este enfoque permite que el modelo identifique no solo la presencia de la enfermedad, sino también la fase específica, lo que es crítico para que el agricultor tome decisiones informadas sobre el manejo del cultivo. Sin embargo, entre las limitaciones se incluyen la necesidad de un etiquetado manual y experto de las imágenes, lo cual requiere tiempo y recursos. Además, el modelo, entrenado con un conjunto de datos específicos, podría no generalizar perfectamente a otras regiones geográficas, climas o variedades de cacao.

Finalmente, las exigencias computacionales del modelo dificultan su ejecución directamente en dispositivos móviles, lo que motiva la necesidad de un servidor remoto para el procesamiento en tiempo real. Los resultados se presentaron de manera visual y numérica para facilitar su interpretación. Se mostraron ejemplos de imágenes originales junto a sus respectivas segmentaciones predichas, resaltando cada fase de la enfermedad con un color distinto. Adicionalmente, se incluyeron tablas con los valores promedio de *Accuracy*, *Precision*, *Recall* y *F1-Score* obtenidos en el conjunto de prueba para cada fase, acompañadas de breves explicaciones sobre el significado y relevancia de cada métrica. Las matrices de confusión también se expusieron de manera sencilla, mostrando la cantidad de aciertos y errores en cada fase.

Por último, se ofreció un análisis narrativo que interpreta las métricas y las visualizaciones, evitando el uso de tecnicismos complejos, con el fin de que el lector, independientemente de su experiencia técnica, pudiera comprender el valor práctico y las fortalezas del sistema.

- **Implementación Técnica Procesamiento de Imágenes**

- **Captura Móvil:** El agricultor toma la fotografía directamente desde la aplicación.

- **Envío y Almacenamiento:** La imagen se transmite al servidor y se almacena en la base de datos.

- **Procesamiento con U-net:**

- El modelo previamente entrenado analiza la imagen.

- Realiza segmentación semántica identificando las diferentes etapas
 - Genera una imagen segmentada con las zonas afectadas.



○ Produce un diagnóstico textual del estado de la enfermedad.

• **Beneficios para el Agricultor**

- Diagnóstico rápido y preciso
- Visualización del estado de la enfermedad
- Posibilidad de intervención temprana
- Registro histórico de la evolución de la enfermedad en sus cultivos

KÄKÄWOL utiliza una combinación de tecnologías de código abierto y propietarias para el desarrollo del prototipo donde se utiliza:

- Visual Studio Code, un editor de código fuente gratuito.
- Lenguaje de programación Dart para la creación de aplicaciones móviles.
- La inteligencia artificial se establece mediante redes neuronales convolucionales (CNN) utilizando:
 - Python (lenguaje de programación)
 - TensorFlow (biblioteca para aprendizaje automático).
 - El backend se desarrolla con Django, framework para Python y se utiliza PostgreSQL, un sistema de gestor de bases de datos relacionales.



La infraestructura incluye

- Dispositivos Android (smartphones y tabletas) para los usuarios.
- Equipos de cómputo para el desarrollo y entrenamiento de modelos.
- Servidores para almacenamiento del modelo final y datos mediante servicios en la nube.

RESULTADOS

Los resultados más recientes, obtenidos a partir de un conjunto de datos limitado debido a la falta de imágenes de mazorcas en época de cosecha, revelaron diferencias en el desempeño de la segmentación entre las distintas clases (*fases de la enfermedad y la clase sin afectación*).

En concreto, la **clase principal** (*asociada a la zona sana o sin enfermedad*) alcanzó valores altos de precisión (0.9006) y **recall** (0.9502), mostrando una capacidad adecuada para diferenciar las áreas sanas. Sin embargo, en las clases correspondientes a las fases de la enfermedad, las métricas fueron más bajas: por ejemplo, la **clase 1** alcanzó un **F1-score** de 0.4245, mientras que las **clases 2, 3 y 4** mostraron dificultades notables con F1-scores de 0.0355, 0.0806 y 0.0091 respectivamente. Estos hallazgos indican un desequilibrio en el rendimiento del modelo, que identifica con mayor facilidad las áreas no afectadas, pero presenta problemas para reconocer y segmentar de forma confiable las fases de la moniliasis.

Si bien el objetivo inicial era identificar y segmentar con precisión las distintas fases de la moniliasis en las mazorcas de cacao, *los resultados obtenidos hasta el momento solo cumplen parcialmente esta meta*.

Por un lado, se logra diferenciar las zonas sanas de manera consistente, lo que es un paso importante hacia el diagnóstico automático. Por otra parte, las fases de la enfermedad no se distinguen con el nivel de fiabilidad esperado, lo que indica que aún se requieren mejoras en el modelo, la calidad o cantidad de datos, o en las condiciones de entrenamiento para cumplir plenamente los objetivos planteados.

Una limitación crucial es el número limitado de imágenes de mazorcas disponibles, debido a que no se obtuvo un conjunto de datos suficientemente variado o representativo de las distintas fases de la enfermedad. Esta carencia de datos puede afectar la capacidad del modelo para generalizar y reconocer patrones en condiciones distintas a las entrenadas. Asimismo, las bajas métricas en las clases de enfermedad sugieren la necesidad de obtener más ejemplos de imágenes anotadas o ajustar la arquitectura y los parámetros del modelo para mejorar su capacidad de segmentación de las fases de la moniliasis. Estas



limitaciones deben ser consideradas al interpretar los resultados y antes de trasladar el modelo a un entorno de uso real. Las observaciones más significativas incluyen:

- La clase sin enfermedad se segmentó con mayor precisión y sensibilidad, lo que sugiere que el modelo distingue con relativa facilidad las áreas sanas de la mazorca.
- Las fases de la enfermedad mostraron un bajo nivel de precisión, recall y F1-score, evidenciando dificultades del modelo para identificar con exactitud las distintas etapas de la moniliasis.
- Existe una disparidad notable en el rendimiento entre la clase saludable y las clases que representan las fases de infección, lo que se refleja claramente en las métricas cuantitativas.

• Precisión de Diagnóstico

- Métrica:** Tasa de aciertos en la detección de moniliasis.
- Resultado:** El modelo de IA logró una precisión del *68% en la identificación de áreas afectadas.

• Estabilidad del Sistema

- Métrica:** Tiempo de operación sin interrupciones.
- Resultado:** El sistema operó sin interrupciones durante 100 cargas de imágenes.

• Tiempo de Respuesta

- Métrica:** Tiempo promedio desde la carga de la imagen hasta la entrega del diagnóstico.
- Resultado:** Tiempo de respuesta promedio de 1.5 minutos.

De acuerdo con el Nivel de Madurez de Tecnología, KÄKÄWOL se encuentra en la etapa TRL 5: *“El prototipo propuesto se somete a diversos análisis en entornos relevantes, pero aún en condiciones controladas”*. Los resultados obtenidos en esta etapa cumplen con los requisitos, demostrando que KÄKÄWOL puede identificar la moniliasis en un entorno controlado de manera estable y con una precisión aceptable.

• Próximos Pasos

1. Optimizar el modelo de IA para mejorar la precisión en imágenes con condiciones variables.
2. Planificar pruebas en un entorno menos controlado para avanzar hacia TRL 6.

Nota

* El porcentaje del 68% es inferior a lo esperado debido a la falta de imágenes que se requieren para entrenar el modelo (la producción es escasa en esta época). Se espera que, al incorporar imágenes de



cultivos de cacao, el modelo pueda mejorar su capacidad de identificación y diagnóstico, alcanzando niveles de precisión superiores.

DISCUSIÓN Y CONCLUSIONES

Discusión

Los hallazgos más importantes de esta investigación se centran en la capacidad del modelo para distinguir, con relativa eficacia, las zonas sanas de las mazorcas de cacao y su dificultad para identificar con precisión las distintas fases de la moniliasis. Mientras que la **clase** correspondiente a “*sin enfermedad*” **obtuvo métricas sólidas** (con una combinación favorable de precisión, sensibilidad y F1-score), las clases que representan las etapas de la enfermedad mostraron un desempeño significativamente menor, reflejando problemas para segmentar de forma confiable dichas zonas afectadas. Estos resultados guardan una relación estrecha con el material y el método empleados.

El uso de una **arquitectura U-Net** estaba justificado por su eficiencia en tareas de segmentación semántica, sin embargo, el conjunto de datos disponible resultó ser limitado y poco representativo, especialmente para las fases avanzadas de la enfermedad. La recolección de imágenes se vio afectada por la época del año y la disponibilidad real de mazorcas con moniliasis en diversas etapas, lo que influyó directamente en la diversidad y cantidad de ejemplos disponibles para el entrenamiento y validación del modelo. En consecuencia, las deficiencias en el rendimiento del sistema reflejan la necesidad de obtener más datos y una mayor variedad de casos, confirmando que la eficacia de las técnicas empleadas depende en gran medida de la calidad y representatividad de los datos de entrada. La principal aportación de estos resultados radica en la identificación de las fortalezas y debilidades actuales del sistema. A nivel práctico, el hallazgo de que el modelo segmenta fácilmente las zonas sanas sirve como base para identificar rápidamente áreas sin infección, lo que podría ahorrar tiempo al agricultor. No obstante, las dificultades en detectar con precisión las fases de la enfermedad resaltan la necesidad de refinar el proceso de adquisición de datos, mejorar el etiquetado, o bien explorar ajustes en el modelo o metodologías complementarias. Estas consideraciones tienen implicaciones directas en la posible implementación de la solución en el campo, ya que un diagnóstico certero de la fase de la moniliasis es clave para la toma de decisiones agronómicas adecuadas.



Como principales limitaciones, es fundamental reconocer que los resultados actuales se basan en un conjunto de datos restringido en número y diversidad. Esto impide una generalización sólida del modelo a diferentes condiciones ambientales, variedades de cacao o estados fenológicos, por lo que los resultados deben ser interpretados con cautela. Además, el bajo rendimiento en las clases de enfermedad indica que la arquitectura y/o el entrenamiento podrían requerir ajustes, así como la inclusión de técnicas de aumento de datos (*data augmentation*) para mejorar la robustez del modelo.

CONCLUSIONES

En términos generales, la investigación demuestra que es posible desarrollar un sistema de segmentación que distinga entre áreas sanas y afectadas en mazorcas de cacao utilizando un modelo basado en U-Net, pero que aún se enfrenta a serias limitaciones a la hora de diferenciar las fases específicas de la moniliasis. El desempeño del modelo está directamente condicionado por la cantidad y calidad de los datos, lo que sugiere que las próximas líneas de investigación deben orientarse hacia la obtención de un conjunto de datos más amplio, la inclusión de imágenes capturadas en diversas condiciones y la aplicación de técnicas más avanzadas de procesamiento de datos o regularización del modelo. A futuro, se recomienda:

- Ampliar la base de datos incorporando más imágenes de mazorcas con diversas etapas de la moniliasis.
- Explorar enfoques adicionales, como otras arquitecturas de redes neuronales o métodos de transferencia de aprendizaje, para mejorar la detección de las fases de la enfermedad.
- Integrar herramientas de aumento de datos o anotaciones más detalladas que puedan brindar mayor información al modelo durante el entrenamiento.
- Evaluar el desempeño del sistema en distintos entornos y condiciones agronómicas, validando su aplicabilidad en escenarios reales.

Estas acciones, en conjunto, permitirán refinar la propuesta y acercar la solución a un escenario práctico donde el agricultor pueda contar con una herramienta confiable para el manejo oportuno de la moniliasis en cacao.

REFERENCIAS BIBLIOGRÁFICAS

Barrera, A., Guindel, C., García, F., & Martín, D. (sf). *Análisis, evaluación e implementación de algoritmos de segmentación semántica para su aplicación en vehículos inteligentes*. Laboratorio de Sistemas Inteligentes (LSI), Universidad Carlos III de Madrid.



- Curiale, A. H., Calandrelli, M. E., & Dellazoppa, L. (s.f.). *Cuantificación automática de los volúmenes y función de ambos ventrículos en resonancia cardíaca: Propuesta y evaluación de un método de inteligencia artificial.*
- Pérez López, B., Resino Solis, M., García Fernández, F., Hussein, A., & Al-Kaff, A. (2019). *Estimación de área glaciar utilizando redes neuronales convolucionales U-Net en imágenes multiespectrales Sentinel-2 en el glaciar Ausangate, 2019.*
- Quihui-Rubio, P. C., Ochoa-Ruiz, G., Gonzalez-Mendoza, M., Rodriguez-Hernandez, G., & Mata, C. (s.f.). *Comparison of automatic prostate zones segmentation models in MRI images using U-net-like architectures.*
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. arXiv preprint arXiv:1505.04597.
<https://doi.org/10.48550/arXiv.1505.04597>
- Zhou, Z., Siddiquee, M. M. R., Tajbakhsh, N., & Liang, J. (2018). UNet++: A Nested U-Net Architecture for Medical Image Segmentation. arXiv preprint arXiv:1807.10165.
<https://doi.org/10.48550/arXiv.1807.10165>
- Aprende Machine Learning. (s.f.). *Cómo funcionan las Convolutional Neural Networks (visión por ordenador).*
<https://www.aprendemachinelearning.com/como-funcionan-las-convolutional-neural-networks-vision-por-ordenador/>
- TensorFlow. (s.f.). *Introducción a TensorFlow para principiantes.*
<https://www.tensorflow.org/tutorials/quickstart/beginner?hl=es-419>
- TensorFlow. (s.f.). *Clasificación básica con Keras.*
<https://www.tensorflow.org/tutorials/keras/classification?hl=es-419>
- TensorFlow. (s.f.). *Redes neuronales convolucionales (CNN).*
<https://www.tensorflow.org/tutorials/images/cnn?hl=es-419>
- TensorFlow. (s.f.). *Aprendizaje por transferencia con Keras.*
https://www.tensorflow.org/tutorials/images/transfer_learning?hl=es-419
- TensorFlow. (s.f.). *Clasificación de imágenes con TensorFlow.*



<https://www.tensorflow.org/tutorials/images/classification?hl=es-419>

Towards ML. (2018). *Understanding convolutional neural networks*.

<https://towardsml.wordpress.com/2018/10/16/deep-learning-series-p2-understanding-convolutional-neural-networks/>

Stanford University. (s.f.). *CS231n: Convolutional Neural Networks for Visual Recognition*.

<https://cs231n.github.io/>

Towards Data Science. (2018). *Intuitively understanding convolutions for deep learning*.

<https://towardsdatascience.com/intuitively-understanding-convolutions-for-deep-learning-1f6f42faee1>

Distill. (2017). *Feature visualization*.

<https://distill.pub/2017/feature-visualization/>

Becoming Human. (s.f.). *Back-propagation in convolutional neural networks*.

<https://becominghuman.ai/back-propagation-in-convolutional-neural-networks-intuition-and-code-714ef1c38199>

Technology Made Easy. (s.f.). *The best explanation of convolutional neural networks on the internet*.

<https://medium.com/technologymadeeasy/the-best-explanation-of-convolutional-neural-networks-on-the-internet-fbb8b1ad5df8>

Ronneberger, O. (s.f.). *U-Net: Convolutional networks for biomedical image segmentation*.

<https://lmb.informatik.uni-freiburg.de/people/ronneber/u-net/>

Ferro, R. (s.f.). *U-Net Implementation*.

https://colab.research.google.com/github/RodolfoFerro/unetworkshop/blob/main/U_Net_Implementation.ipynb

La Máquina Oráculo. (s.f.). *U-Net y segmentación semántica*.

<https://lamaquinaoraculo.com/deep-learning/u-net-y-segmentacion-semantica/>

PyImageSearch. (2022). *U-Net: Image segmentation in Keras*.

<https://pyimagesearch.com/2022/02/21/u-net-image-segmentation-in-keras/>

Hackers Realm. (s.f.). *Image segmentation with U-Net in Keras and TensorFlow*.

<https://www.hackersrealm.net/post/image-segmentation-unet-keras-tensorflow>



DigitalOcean. (s.f.). *U-Net architecture for image segmentation*.

<https://www.digitalocean.com/community/tutorials/unet-architecture-image-segmentation>

Machine Learning Nuggets. (s.f.). *Image segmentation with U-Net from scratch*.

<https://www.machinelearningnuggets.com/image-segmentation-with-u-net-define-u-net-model-from-scratch-in-keras-and-tensorflow/>

DzLab. (2021). *U-Net transfer learning*.

https://colab.research.google.com/github/dzlab/notebooks/blob/master/notebooks/2021-06-13-U_Net_transfer_learning.ipynb

Keras. (s.f.). *Oxford Pets image segmentation with U-Net*.

https://keras.io/examples/vision/oxford_pets_image_segmentation/

Idiot Developer. (s.f.). *U-Net implementation in TensorFlow*.

<https://idiotdeveloper.com/unet-implementation-in-tensorflow-using-keras-api/>

Toolify. (s.f.). *Entrenamiento de U-Net en un conjunto de datos original: Tutorial paso a paso*.

<https://www.toolify.ai/es/ai-news-es/entrenamiento-de-unet-en-un-conjunto-de-datos-original-tutorial-paso-a-paso-585772>

DataScientest. (s.f.). *U-Net: Lo que tienes que saber*.

<https://datascientest.com/es/u-net-lo-que-tienes-que-saber>

Inteligencia Artificial 360. (s.f.). *U-Net*.

<https://inteligenciaartificial360.com/glosario/u-net/>

Wikiwand. (s.f.). *U-Net*.

<https://www.wikiwand.com/es/articles/U-Net>

