



**UNIVERSIDAD
DE ANTIOQUIA**

**Mejoramiento del modelo de Deep Learning y ampliación del módulo de análisis
cefalométrico en el software DIACEFAL**

Teodoro Rafael Calle Lara

Trabajo de grado presentado para optar al título de Ingeniero
Electrónico.

Tutores

David Stephen Fernández Mc Cann, (Ph.D.)

Elizabeth Llano Sánchez, (Mg)

Universidad de Antioquia

Facultad de Ingeniería

Ingeniería Electrónica

Medellín

2026



UNIVERSIDAD DE ANTIOQUIA

Cita	T. Calle Lara
Referencia	[1] T. Calle Lara, “Mejoramiento del modelo de Deep Learning y ampliación del módulo de análisis cefalométrico en el software DIACEFAL”, Trabajo de grado, Ingeniería Electronica, Universidad de Antioquia, Medellín 2026.
Estilo IEEE (2020)	



Grupo de Electrónica de Potencia, Automatización y Robótica (GEPAR)

Facultad de Odontología, Universidad de Antioquia

Centro de documentación Ingeniería, CENDOI.

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos

SIGLAS, ACRÓNIMOS Y ABREVIATURAS

COCO	Common Objects in Context
Dataset	Conjunto de datos utilizado para el entrenamiento
DIACEFAL	Sistema para la detección automática de puntos cefalométricos en radiografías laterales de cráneo
DL	Deep Learning
IA	Inteligencia Artificial
Keypoints	Puntos clave
Landmarks	Puntos anatómicos de referencia utilizados en el análisis cefalométrico
mAP	mean Average Precision
YOLO	You Only Look Once

RESUMEN

El análisis cefalométrico constituye una herramienta fundamental en el diagnóstico y planificación de tratamientos en ortodoncia y cirugía maxilofacial, ya que permite evaluar la relación entre las estructuras óseas y dentales del cráneo. Tradicionalmente, este proceso se realiza de manera manual sobre radiografías laterales, lo cual implica un alto grado de conocimiento especializado, un considerable consumo de tiempo y posibles variaciones en la identificación de los puntos anatómicos debido a la subjetividad del observador.

En respuesta a estas limitaciones, han surgido herramientas basadas en inteligencia artificial que buscan automatizar el análisis cefalométrico. En este contexto, el sistema DIACEFAL fue desarrollado inicialmente como una solución orientada a la detección de regiones de interés en radiografías cefalométricas, mediante el uso de técnicas de detección de objetos.

No obstante, la primera versión del sistema presentaba una limitación importante: si bien permitía identificar zonas aproximadas donde se ubicaban los puntos anatómicos, no ofrecía la localización exacta de estos, lo cual afectaba la precisión de las mediciones cefalométricas.

A partir de esta problemática, surge la necesidad de mejorar la precisión en la detección automática de puntos cefalométricos. En este sentido, el presente trabajo se enfoca en la evolución de una solución existente, mediante la transición de un enfoque basado en detección de objetos hacia un enfoque de detección de puntos clave (keypoint detection), que permita obtener coordenadas precisas de los landmarks anatómicos.

De esta manera, se formula la siguiente pregunta de investigación: ¿Cómo mejorar la precisión en la detección automática de puntos cefalométricos en radiografías laterales de cráneo mediante el uso de técnicas de aprendizaje profundo?

En coherencia con lo anterior, el objetivo de este trabajo consiste en mejorar el modelo de Deep Learning implementado en el software DIACEFAL, incrementando la precisión en la detección de puntos anatómicos cefalométricos y ampliando las mediciones generadas en el módulo de

informes, con el fin de automatizar y mejorar la calidad del análisis cefalométrico como apoyo al diagnóstico clínico.

La relevancia de este trabajo radica en que permite transformar un sistema con limitaciones en precisión en una herramienta más robusta y confiable, contribuyendo a la reducción de la variabilidad en el análisis cefalométrico y al apoyo en la toma de decisiones clínicas. Asimismo, este desarrollo evidencia el potencial de la inteligencia artificial para mejorar soluciones existentes en el ámbito de la salud, incrementando su aplicabilidad, precisión y utilidad en entornos clínicos reales.

Palabras clave — inteligencia artificial, deep learning, cefalometría, detección de puntos clave, visión por computadora.

ABSTRACT

Cephalometric analysis is a fundamental tool in the diagnosis and treatment planning in orthodontics and maxillofacial surgery, as it allows the evaluation of the relationships between craniofacial skeletal and dental structures. Traditionally, this process is performed manually on lateral radiographs, requiring a high level of expertise, significant time investment, and being subject to variability due to observer interpretation.

To address these limitations, artificial intelligence-based approaches have emerged to automate cephalometric analysis. In this context, the DIACEFAL system was initially developed as a solution focused on detecting regions of interest in cephalometric radiographs using object detection techniques.

However, the first version of the system presented a key limitation: although it could identify approximate regions of anatomical points, it did not provide their exact localization, which negatively impacted the accuracy of cephalometric measurements.

Based on this problem, this work focuses on improving the precision of automatic landmark detection by transitioning from an object detection approach to a keypoint detection approach, enabling the prediction of precise coordinates for anatomical landmarks.

Accordingly, the research addresses the following question: how can the accuracy of automatic cephalometric landmark detection in lateral skull radiographs be improved using deep learning techniques?

In line with this, the objective of this work is to enhance the Deep Learning model implemented in the DIACEFAL software by increasing the accuracy of anatomical landmark detection and expanding the measurements generated in the reporting module, in order to automate and improve the quality of cephalometric analysis for clinical decision support.

The relevance of this work lies in transforming a system with precision limitations into a more robust and reliable tool, contributing to the reduction of variability in cephalometric analysis and supporting clinical decision-making. Furthermore, this development highlights the potential of artificial intelligence to improve existing healthcare solutions, increasing their applicability, accuracy, and usefulness in real clinical environments.

***Keywords* — artificial intelligence, deep learning, cephalometry, keypoint detection, computer vision.**

I. INTRODUCCIÓN

El análisis cefalométrico constituye una herramienta fundamental en el diagnóstico y planificación de tratamientos en ortodoncia y cirugía maxilofacial, ya que permite evaluar la relación entre las estructuras óseas y dentales del cráneo. Tradicionalmente, este proceso se realiza de manera manual sobre radiografías laterales, lo cual implica un alto grado de conocimiento especializado, un considerable consumo de tiempo y posibles variaciones en la identificación de los puntos anatómicos debido a la subjetividad del observador.

En respuesta a estas limitaciones, han surgido herramientas basadas en inteligencia artificial que buscan automatizar el análisis cefalométrico. En este contexto, el sistema DIACEFAL fue desarrollado inicialmente como una solución orientada a la detección de regiones de interés en radiografías cefalométricas, mediante el uso de técnicas de detección de objetos.

No obstante, la primera versión del sistema presentaba una limitación importante: si bien permitía identificar zonas aproximadas donde se ubicaban los puntos anatómicos, no ofrecía la localización exacta de estos, lo cual afectaba la precisión de las mediciones cefalométricas.




Ilustración 1 Detección de regiones en la versión 1 de DIACEFAL.

A partir de esta problemática, surge la necesidad de mejorar la precisión en la detección automática de puntos cefalométricos. En este sentido, el presente trabajo no plantea el desarrollo de un sistema desde cero, sino la evolución de una solución existente, mediante la transición de un enfoque basado en detección de objetos hacia un enfoque de detección de puntos clave (keypoint detection).

De esta manera, se formula la siguiente pregunta de investigación: ¿Cómo mejorar la precisión en la detección automática de puntos cefalométricos en radiografías laterales de cráneo mediante el uso de técnicas de aprendizaje profundo?

Para dar respuesta a esta interrogante, se propone el desarrollo de la segunda versión del sistema DIACEFAL, en la cual se implementa un modelo basado en la arquitectura YOLOv11, capaz de predecir coordenadas precisas de los landmarks cefalométricos. Este enfoque se complementa con técnicas de preprocesamiento y aumento de datos, con el fin de mejorar la capacidad de generalización del modelo.

La relevancia de este trabajo radica en que permite transformar un sistema con limitaciones en precisión en una herramienta más robusta y confiable, contribuyendo a la reducción de la variabilidad en el análisis cefalométrico y al apoyo en la toma de decisiones clínicas. Asimismo, este desarrollo evidencia el potencial de la inteligencia artificial para mejorar soluciones existentes en el ámbito de la salud, incrementando su aplicabilidad y desempeño.

II. OBJETIVOS

A. Objetivo general

Mejorar el modelo de Deep Learning implementado en el software DIACEFAL, incrementando su precisión en la detección de puntos anatómicos cefalométricos y ampliando las mediciones y análisis generados en el módulo de informes, con el fin de automatizar y mejorar la calidad del análisis cefalométrico como apoyo al diagnóstico clínico.

B. Objetivos específicos

1. Etiquetar nuevamente las radiografías digitalizadas incorporando los puntos ICI, ICS, AiCS, AiCi mediante el uso de las herramientas de Roboflow para generar el nuevo dataset.
2. Entrenar un nuevo modelo de Deep Learning con mayor exactitud, mediante el nuevo dataset para la localización automática de puntos cefalométricos, utilizando procesamiento digital de imágenes y técnicas de aprendizaje profundo.
3. Incorporar nuevas medidas angulares y lineales en el informe cefalométrico del software DIACEFAL, teniendo en cuenta los nuevos puntos.
4. Ajustar y validar los rangos de normalidad de las medidas existentes con base en literatura científica actualizada.
5. Evaluar el rendimiento del nuevo modelo de detección de puntos anatómicos comparado con la versión anterior basada en detección de objetos, mediante el análisis del nivel de confianza asociado a la predicción de cada landmark cefalométrico, como indicador de fiabilidad y estabilidad del modelo en la identificación de puntos anatómicos.

III. MARCO TEÓRICO

3.1 Análisis cefalométrico

El análisis cefalométrico es un procedimiento ampliamente utilizado en ortodoncia y cirugía maxilofacial para evaluar la relación entre estructuras óseas y dentales del cráneo. Este análisis se basa en la identificación de puntos anatómicos específicos, conocidos como landmarks, los cuales permiten realizar mediciones angulares y lineales relevantes para el diagnóstico clínico [1].

Tradicionalmente, este proceso se realiza de manera manual sobre radiografías laterales de cráneo, lo que implica un alto grado de experiencia por parte del especialista y puede introducir variabilidad en los resultados debido a la subjetividad en la localización de los puntos [2].

3.2 Inteligencia artificial y aprendizaje profundo

La inteligencia artificial (IA) ha permitido el desarrollo de sistemas capaces de simular procesos cognitivos humanos, siendo el aprendizaje profundo (Deep Learning) una de sus ramas más relevantes en la actualidad. Este enfoque se basa en redes neuronales profundas que permiten el aprendizaje automático a partir de grandes volúmenes de datos [3].

Diversos estudios han demostrado que los modelos de aprendizaje profundo pueden alcanzar niveles de precisión comparables o incluso superiores a los de expertos humanos en tareas de análisis de imágenes médicas [4].

3.3 Visión por computadora en imágenes médicas

La visión por computadora es un área de la inteligencia artificial que permite a las máquinas interpretar y analizar información visual. En el ámbito médico, esta disciplina ha sido aplicada en la detección de anomalías, segmentación de estructuras y análisis automatizado de imágenes diagnósticas [5].

En el caso del análisis cefalométrico, el uso de modelos de visión por computadora permite automatizar la identificación de puntos anatómicos, reduciendo el tiempo de análisis y mejorando la consistencia de los resultados [6].

3.4 Modelos de detección de objetos

Los modelos de detección de objetos tienen como objetivo identificar y localizar elementos dentro de una imagen mediante el uso de cuadros delimitadores (bounding boxes). Entre las arquitecturas más destacadas se encuentra YOLO (You Only Look Once), caracterizada por su capacidad de realizar detecciones en tiempo real con alta eficiencia [7].

Sin embargo, este tipo de modelos presenta limitaciones cuando se requiere alta precisión en la localización de puntos específicos, ya que su enfoque se centra en regiones y no en coordenadas exactas [8].

3.5 Detección de puntos clave (Keypoint Detection)

La detección de puntos clave es una técnica que permite identificar coordenadas específicas dentro de una imagen, representando características relevantes del objeto analizado. Este enfoque resulta especialmente útil en aplicaciones donde la precisión espacial es crítica, como en el análisis cefalométrico [9].

A diferencia de la detección de objetos, los modelos de keypoints proporcionan directamente la ubicación exacta de cada punto, lo que permite realizar mediciones más precisas y confiables [10].

3.6 Transferencia de aprendizaje

La transferencia de aprendizaje (transfer learning) consiste en reutilizar modelos previamente entrenados en grandes conjuntos de datos para resolver problemas específicos con menor cantidad de información. Esta técnica permite reducir el tiempo de entrenamiento y mejorar el desempeño del modelo [11].

En aplicaciones de visión por computadora, es común utilizar modelos preentrenados en datasets como COCO, los cuales contienen una amplia variedad de imágenes y anotaciones [12].

3.7 Aumento de datos (Data Augmentation)

El aumento de datos es una técnica utilizada para incrementar artificialmente el tamaño y diversidad de un dataset mediante transformaciones como rotaciones, cambios de brillo, ruido y desenfoque. Esto contribuye a mejorar la capacidad de generalización de los modelos de aprendizaje profundo [13].

Diversos autores coinciden en que el uso de data augmentation reduce el sobreajuste y mejora el desempeño en escenarios reales [14].

IV. METODOLOGÍA

La metodología del presente trabajo se estructuró en diferentes etapas orientadas al cumplimiento de los objetivos planteados. Estas etapas incluyeron la preparación y etiquetado del dataset, el entrenamiento del modelo de Deep Learning, la ampliación del módulo de análisis cefalométrico, la validación de los resultados obtenidos y la integración del modelo en el sistema DIACEFAL.

Objetivos	Actividades
Etiquetar nuevamente las radiografías digitalizadas adicionando los puntos ICI, ICS, AiCS, AiCi mediante el uso de las herramientas de Roboflow para generar el nuevo dataset.	• Adicionar los 4 puntos a cada radiografía del dataset. • Aprender cómo hacer el etiquetado.
Entrenar un nuevo modelo de Deep Learning con mayor exactitud, mediante el nuevo dataset para la localización automática de puntos cefalométricos, utilizando procesamiento digital de imágenes y técnicas de aprendizaje profundo.	• Revisión del código fuente existente del software DIACEFAL. • Análisis del modelo de Deep Learning actualmente implementado, basado en detección de objetos. • Entrenamiento del modelo utilizando el dataset preparado.
Incorporar nuevas medidas angulares y lineales en el informe cefalométrico del software DIACEFAL, teniendo en cuenta los nuevos puntos.	• Calcular la longitud de la rama. • Calcular los ángulos interdentes. • Permitir la descarga del análisis en formato PDF. • Adicionar la información en la interfaz de usuario.
Ajustar y validar los rangos de normalidad de las medidas existentes con base en literatura científica actualizada.	• Revisar las medidas preexistentes. • Ajustar las medidas con base en literatura especializada.
Evaluar el rendimiento del nuevo modelo de detección de puntos anatómicos comparado con la versión anterior basada en detección de objetos, mediante el análisis del nivel de confianza asociado a la predicción de cada landmark cefalométrico, como indicador de fiabilidad y estabilidad del modelo en la identificación de puntos anatómicos.	• Ejecutar pruebas funcionales y de rendimiento. • Comparar resultados con respecto al modelo basado en detección de objetos

Las herramientas utilizadas incluyeron:

- Roboflow para la gestión del dataset, anotación y entrenamiento del modelo.
- YOLOv11 con arquitectura basada en COCO-pose para la detección de puntos clave.

- Lenguaje Java para la integración del modelo en el software DIACEFAL.
- Técnicas de procesamiento digital de imágenes para el preprocesamiento.

V. ANÁLISIS DE RESULTADOS

5.1 Detección de puntos

El modelo desarrollado logra identificar los landmarks cefalométricos con alta precisión, generando coordenadas exactas sobre las radiografías.




Ilustración 2 Detección de puntos cefalométricos en DIACEFAL versión 2.

5.2 Nivel de confianza

El modelo presenta valores de confianza en sus predicciones dentro de un rango de 0.988 a 1.0, con un promedio cercano a 1.0. Estos resultados indican una alta fiabilidad en la detección de los puntos cefalométricos, ya que reflejan una elevada probabilidad asignada por el modelo a la correcta localización de cada landmark.

5.3 Métricas de desempeño

El modelo alcanzó un valor de mAP50 del 100% tanto en el conjunto de validación como en el conjunto de prueba. Estos resultados evidencian un alto desempeño en la detección de los puntos cefalométricos, así como una adecuada capacidad de generalización dentro del dataset evaluado.

5.4 Comportamiento del entrenamiento

Durante el proceso de entrenamiento, el modelo presentó una convergencia estable, evidenciada en la evolución de las métricas de desempeño y en la disminución progresiva de las funciones de pérdida.

La métrica mAP alcanzó valores cercanos a 1.0 en etapas tempranas del entrenamiento, manteniéndose estable durante la mayoría de las épocas, lo que indica una rápida capacidad de aprendizaje del modelo.

La Box Loss mostró una reducción significativa a lo largo del entrenamiento, pasando de valores iniciales cercanos a 0.8 a valores finales alrededor de 0.1, evidenciando una mejora progresiva en la precisión de localización de los puntos anatómicos.

La Class Loss presentó una disminución general con ligeras variaciones, estabilizándose en valores bajos, lo que indica una correcta identificación de las clases asociadas a los puntos cefalométricos.

Finalmente, la Object Loss evidenció una tendencia descendente durante el entrenamiento, lo que indica una mejora en la capacidad del modelo para detectar la presencia de objetos relevantes en la imagen. Aunque se presentan ligeras variaciones y un incremento puntual en etapas finales, la tendencia general confirma una adecuada convergencia.




Ilustración 3 Comportamiento del desempeño del modelo (mAP) durante el entrenamiento.




Ilustración 4 Evolución de la función de pérdida de localización (Box Loss).




Ilustración 5 Evolución de la función de pérdida de clasificación (Class Loss).




Ilustración 6 Evolución de la función de pérdida de objeto (Object Loss).

5.5 Comparación con DIACEFAL versión 1

El modelo implementado en la versión 1 de DIACEFAL se basaba en un enfoque de detección de objetos, el cual permitía identificar regiones de interés mediante el uso de cajas delimitadoras (bounding boxes).

A partir de los resultados obtenidos, se observa que, aunque el modelo alcanzó valores altos de mAP (cercanos al 100%), la métrica mAP50-95 presentó valores inferiores y una mayor variabilidad durante el entrenamiento, lo que evidencia limitaciones en la precisión de localización y en la consistencia del modelo.




Ilustración 7 Desempeño del modelo en DIACEFAL versión 1.

En contraste, la versión 2 del sistema emplea un enfoque basado en detección de puntos clave (keypoint detection), permitiendo la obtención directa de coordenadas exactas de los puntos cefalométricos.

Además, el modelo desarrollado en la versión 2 presenta una mayor estabilidad en el entrenamiento, evidenciada en la consistencia de las métricas y en la convergencia de las

funciones de pérdida, lo que se traduce en una mejora significativa en la precisión del análisis cefalométrico.

Comparación de Box Loss entre versiones

El análisis de la función de pérdida (Box Loss) evidencia diferencias significativas entre la versión 1 y la versión 2 del sistema DIACEFAL.

En la versión 1, se observa un valor inicial elevado cercano a 3.0, seguido de una disminución progresiva con alta variabilidad durante el entrenamiento. Esta inestabilidad se manifiesta en múltiples oscilaciones y en un incremento puntual en etapas finales, lo que indica una convergencia parcial del modelo.

En contraste, la versión 2 presenta valores iniciales considerablemente menores y una reducción sostenida de la pérdida, alcanzando valores cercanos a 0.1 con una mayor estabilidad. Esto evidencia una mejora significativa en la precisión de localización de los puntos anatómicos y en la robustez del proceso de entrenamiento.




Ilustración 8 Evolución de la función de pérdida de localización (Box Loss) del modelo en DIACEFAL versión 1.

Comparación de Class Loss entre versiones

La función de pérdida de clasificación (Class Loss) en la versión 1 presenta una disminución progresiva y una estabilización en valores bajos, lo que indica que el modelo logra identificar adecuadamente las clases asociadas a los puntos anatómicos.

Sin embargo, al comparar este comportamiento con la versión 2, se evidencia que, aunque ambos modelos presentan un desempeño adecuado en la clasificación, la principal mejora se encuentra en la localización de los puntos, reflejada en la reducción significativa de la Box Loss en la versión más reciente.




Ilustración 9 Evolución de la función de pérdida de clasificación (Class Loss) del modelo en DIACEFAL versión 1.

Comparación de Object Loss entre versiones

La función de pérdida de objeto (Object Loss) en la versión 1 presenta una disminución progresiva desde valores iniciales elevados, estabilizándose en torno a valores cercanos a 1.0. Sin embargo, se observan fluctuaciones durante el entrenamiento y un incremento puntual en etapas finales, lo que sugiere una convergencia parcial del modelo.

En contraste, la versión 2 muestra una reducción más consistente y estable de esta métrica, alcanzando valores significativamente menores, lo que indica una mejor capacidad del modelo para identificar correctamente las regiones relevantes asociadas a los puntos cefalométricos.




Ilustración 10 Evolución de la función de pérdida de objeto (Object Loss) del modelo en DIACEFAL versión 1.

En conjunto, estos resultados evidencian que la versión 2 del sistema DIACEFAL no solo mejora la estabilidad del entrenamiento, sino que incrementa significativamente la precisión en la localización de los puntos cefalométricos, superando las limitaciones del enfoque basado en detección de objetos implementado en la versión 1.

VI. CONCLUSIONES Y RECOMENDACIONES

El desarrollo de la segunda versión del software DIACEFAL permitió mejorar significativamente el modelo de Deep Learning utilizado para la detección de puntos cefalométricos, logrando una mayor precisión en la localización de los landmarks anatómicos en radiografías laterales de cráneo.

La migración de un enfoque basado en detección de objetos hacia un modelo de detección de puntos clave (keypoint detection) representó un avance fundamental, ya que permitió obtener coordenadas exactas de los puntos anatómicos, eliminando la ambigüedad asociada a las regiones detectadas mediante bounding boxes en la versión anterior.

Los resultados obtenidos evidencian un alto desempeño del modelo propuesto, alcanzando valores de mAP50 del 100% en los conjuntos de validación y prueba, así como niveles de confianza cercanos a 1.0 en la predicción de los puntos cefalométricos, lo que demuestra una alta fiabilidad del sistema.

El análisis del comportamiento del entrenamiento mostró una convergencia estable en la versión 2, reflejada en la disminución sostenida de las funciones de pérdida (Box Loss, Class Loss y Object Loss), en contraste con la versión 1, la cual presentó mayor variabilidad e inestabilidad, especialmente en la localización de los puntos.

Asimismo, la comparación entre ambas versiones permitió identificar que, aunque el modelo anterior presentaba un desempeño adecuado en la clasificación de los puntos, existían limitaciones en su precisión espacial. Estas limitaciones fueron superadas en la versión 2, donde se logró una mejora significativa en la localización, manteniendo al mismo tiempo una adecuada capacidad de clasificación y detección.

Adicionalmente, la integración del modelo en el software DIACEFAL permitió automatizar el análisis cefalométrico, incluyendo la incorporación de nuevas medidas y la actualización de rangos clínicos, lo que incrementa la utilidad del sistema como herramienta de apoyo al diagnóstico ortodóntico.

En conjunto, los resultados obtenidos confirman que el modelo desarrollado no solo mejora el desempeño técnico del sistema, sino que también aporta valor clínico, al ofrecer un análisis más

preciso, consistente y confiable, consolidando a DIACEFAL como una solución robusta para el análisis cefalométrico asistido por inteligencia artificial.

REFERENCIAS

- [1] W. R. Proffit, H. W. Fields y D. M. Sarver, *Contemporary Orthodontics*, 5th ed. St. Louis, MO, USA: Elsevier, 2013.
- [2] S. Baumrind y D. Frantz, “The reliability of head film measurements,” *American Journal of Orthodontics*, vol. 60, no. 2, pp. 111–127, 1971.
- [3] I. Goodfellow, Y. Bengio y A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.
- [4] G. Litjens et al., “A survey on deep learning in medical image analysis,” *Medical Image Analysis*, vol. 42, pp. 60–88, 2017.
- [5] Y. LeCun, Y. Bengio y G. Hinton, “Deep learning,” *Nature*, vol. 521, pp. 436–444, 2015.
- [6] O. Ronneberger, P. Fischer y T. Brox, “U-Net: Convolutional networks for biomedical image segmentation,” en *MICCAI*, 2015.
- [7] J. Redmon y A. Farhadi, “YOLOv3: An incremental improvement,” 2018.
- [8] K. He, G. Gkioxari, P. Dollár y R. Girshick, “Mask R-CNN,” en *IEEE International Conference on Computer Vision (ICCV)*, 2017.
- [9] Z. Cao et al., “OpenPose: Realtime multi-person 2D pose estimation,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019.
- [10] A. Newell, K. Yang y J. Deng, “Stacked hourglass networks for human pose estimation,” en *ECCV*, 2016.
- [11] S. Ioffe y C. Szegedy, “Batch normalization: Accelerating deep network training,” en *ICML*, 2015.
- [12] D. P. Kingma y J. Ba, “Adam: A method for stochastic optimization,” en *ICLR*, 2015.
- [13] L. Perez y J. Wang, “The effectiveness of data augmentation in image classification using deep learning,” 2017.
- [14] A. Shorten y T. M. Khoshgoftaar, “A survey on image data augmentation for deep learning,” *Journal of Big Data*, vol. 6, no. 60, 2019.