

SEGMENTACION AUTOMÁTICA DE LEUCOCITOS EN IMAGENES DE FROTIS SANGUÍNEO MEDIANTE U-NET++ Y ATTENTION U-NET



UNIVERSIDAD
MODELO
INGENIERÍA

HAYDEE VAZQUEZ GUILLEN, AURA GARRIDO VILLARREAL, ISMAEL PEREZ RUIZ
UNIVERSIDAD MODELO, ESCUELA DE INGENIERÍA, MÉRIDA, MÉXICO

INTRODUCCIÓN

El análisis morfológico de leucocitos es una herramienta para el diagnóstico de enfermedades hematológicas como leucemias, infecciones y trastornos autoinmunes. Sin embargo, la segmentación manual de estas células en imágenes de frotis sanguíneo es un proceso lento, subjetivo y dependiente de la experiencia del especialista. Los avances en *deep learning* han permitido automatizar esta tarea mediante redes neuronales convolucionales. En este trabajo se comparan dos arquitecturas utilizadas para segmentación biomédica: U-Net++ y Attention U-Net, con el objetivo de determinar cuál ofrece un mejor desempeño en la segmentación automática de leucocitos.

ANTECEDENTES

- Alharbi et al. (2022): ResNet + U-Net logró Dice de 96% en segmentación de leucocitos.
- Kotecha et al. (2024): U-Net++ alcanzó ~98% de precisión para diagnóstico de leucemia.
- Jan et al. (2025): U-Net++ + watershed obtuvo Dice de 98.36%, aunque con mayor complejidad computacional.

METODOLOGÍA

Dataset

- Dataset KRD-WBC.
- 600 imágenes RGB de leucocitos.
- Resolución: 512 × 512 píxeles.
- Cinco tipos de leucocitos: Neutrófilos, Linfocitos, Monocitos, Eosinófilos, Basófilos

División de datos

- Entrenamiento: 500 imágenes (83.3%)
- Validación: 50 imágenes (8.3%)
- Prueba: 50 imágenes (8.3%)

Preprocesamiento

- Normalización de imágenes.
- Binarización de máscaras.
- Normalización estadística basada en ImageNet.

Modelos evaluados:

U-Net++

- Backbone ResNet34 preentrenado.
- Dice Loss.
- Scheduler CosineAnnealingLR.

Attention U-Net

- Bloques de atención (Attention Gates).
- BCE + Dice Loss.
- Scheduler ReduceLROnPlateau.

Métricas de evaluación

- Dice Score
- Intersection over Union (IoU)
- Boundary F-Score (BF)
- Distancia de Hausdorff (HD)

RESULTADOS

Fig. 1. Curvas de entrenamiento y validación para ambos modelos. A) Curvas U-Net++: Dice Loss Score, y IoU después de 50 épocas. B) Curvas Attention U-Net: Dice Loss Score, y IoU después de 50 épocas.




Tabla 1. U-Net++ obtuvo la mejor superposición global (Dice e IoU), mientras que Attention U-Net presentó la mejor precisión en bordes celulares (BF y Hausdorff), evidenciando fortalezas complementarias para la segmentación de leucocitos.

Modelo	Dice	IoU	BF	HD (px)
Alharbi et al.	0.96	-	-	-
Kotecha et al.	0.98	-	-	-
Jan et al.	0.9836	0.9773	-	-
U-Net++	0.9509	0.9074	0.6325	11.34
Attention U-Net	0.9415	0.8939	-	7.76

Fig. 2. Ejemplos de Segmentación con U-Net++.

A) Imagen original. B) Mascara real (superposición roja). C) Predicción del modelo





Fig. 3. Ejemplos de Segmentación con Attention U-Net.

A) Imagen original. B) Mascara real (superposición roja). C) Predicción del modelo (superposición azul)



DISCUSIÓN

Los resultados muestran que ambas arquitecturas son efectivas para la segmentación automática de leucocitos. U-Net++ obtuvo los mejores valores de Dice Score e IoU, indicando una mayor superposición global con las máscaras reales. En contraste, Attention U-Net alcanzó el mejor Boundary F-Score y la menor distancia de Hausdorff, evidenciando una delimitación más precisa de los contornos celulares gracias al uso de mecanismos de atención.

CONCLUSIÓN

Se implementaron y compararon las arquitecturas U-Net++ y Attention U-Net para la segmentación automática de leucocitos en imágenes de frotis sanguíneo. Ambos modelos alcanzaron un desempeño elevado, con valores de Dice superiores a 0.94. U-Net++ obtuvo los mejores resultados en Dice Score e IoU, mientras que Attention U-Net destacó en la delimitación de contornos al presentar el mayor Boundary F-Score y la menor distancia de Hausdorff. Estos resultados muestran que ambas arquitecturas son alternativas prometedoras para sistemas automatizados de apoyo al diagnóstico hematológico.

[1] Khorsheed, R., et al.: Creating a white blood cell dataset for segmentation. Mendeley Data, v2 (2023). <https://data.mendeley.com/datasets/jzjd6h7gms/2>

[2] Ronneberger, O., Fischer, P., Brox, T.: U-Net: Convolutional networks for biomedical image segmentation. In: MICCAI, LNCS, vol. 9351, pp. 234-241 (2015)

[3] Oktay, O., et al.: Attention U-Net: Learning where to look for the pancreas. arXiv preprint arXiv:1804.03999 (2018) (Arquitectura Attention U-Net).