

Clasificación de Enfermedades Subcutáneas Provocadas por Hongos mediante Aprendizaje Profundo.

Vania Déborah Vázquez-Palacios, Humberto Pérez-Espinosa, Julio César Pérez Sansalvador
 Instituto Nacional de Astrofísica, Óptica y Electrónica, Luis Enrique Erro No. 1, Tonantzintla, Puebla, 72840, México
 deborah.vazquez@inaoep.mx

RESUMEN

Las enfermedades subcutáneas fúngicas como la cromoblastomycosis, esporotricosis y micetoma representan un reto diagnóstico, especialmente en regiones con recursos limitados (1). El diagnóstico visual asistido por inteligencia artificial puede convertirse en una herramienta de apoyo clínico(2,4).

Se evaluaron tres modelos preentrenados (VGG16, ResNet50 y EfficientNetB0), siendo VGG16 Y ResNet50 los que alcanzaron el mejor desempeño con una precisión de prueba del 88 %.

Palabras clave: aprendizaje profundo, enfermedades subcutáneas, aprendizaje por transferencia, clasificación de imágenes.



Fig. 1 Ejemplo de lesiones subcutáneas causadas por micosis

OBJETIVOS

- Desarrollar y evaluar un sistema de clasificación automática de imágenes clínicas de lesiones subcutáneas provocadas por hongos (cromoblastomycosis, esporotricosis y micetoma), utilizando modelos de aprendizaje profundo y técnicas de aprendizaje por transferencia.
- Implementar un conjunto de modelos preentrenados de aprendizaje profundo (VGG16, ResNet50 y EfficientNetB0) para la clasificación de imágenes clínicas.
- Comparar el desempeño de los modelos en términos de precisión y especificidad.

ANTECEDENTES

AUTORES	ENFERMEDADES ABORDADAS	BASES DE DATOS	ARQUITECTURA USADA	RESULTADOS
Pai et al. 2023 [3]	Celulitis, Impétigo, la Tiña y la Esporotricosis	Recabado por los autores en papers, 500 imágenes.	VGG16, Inception, ResNet-V2, MobileNet y InceptionV3, ResNet101 y ResNet-50	Precisión del 86 % y un puntaje F1 del 85 %
Yotsu et al. 2023 [6]	Úlcera de Buruli, Lepra, Micetoma , Sarna y Pian	Recabado por los autores en pacientes, 1407 imágenes (privada).	ResNet50 y VGG16	ResNet-50 precisión de 84.63% y VGG-16 precisión de 82.22%
Wudi Wei et al. 2023 [5]	Criptococosis y Talarionomicosis	Imágenes obtenidas de artículos publicados en PubMed, WanFang y CNKI, 234 imágenes.	GG19, MobileNet, InceptionV3, InceptionResNetV2 y DenseNet201	VGG19: 82.82% MobileNet: 82.17% InceptionV3: 96.51%
Este trabajo	Cromoblastomycosis, Micetoma, Esporotricosis	Recabado por autores en papers, 78 imágenes	EfficientNetB0, ResNet50 y VGG16	EfficientNetB0: 87% ResNet50: 88% VGG16: 88%

REFERENCIAS

- Bonifaz, A., Vázquez-González, D., & Perusquia-Ortiz, A. M. (2010). Subcutaneous mycoses: chromoblastomycosis, sporotrichosis and mycetoma. Journal of the German Society of Dermatology, 8(8), 619–628. <https://doi.org/10.1111/j.1610-0387.2010.07453.x>
- Janoria, H., Minj, J., & Patre, P. (2020). Classification of Skin Disease from Skin Images Using Transfer Learning Technique. 2020 4th International Conference on Electronics, Communication and Aerospace Technology (ICECA), Coimbatore, India, pp. 888–895. <https://doi.org/10.1109/ICECA49313.2020.9297567>
- Pai, V. R., Pai, S. G., Suhasi, P. M., & Rekha, P. M. (2023). Identification and Classification of Skin Diseases using Deep Learning Techniques. Research Square. <https://doi.org/10.21203/rs.3.rs-2628782/v1>
- Santos, F., Silva, F., & Georgieva, P. (2021). Transfer Learning for Skin Lesion Classification using Convolutional Neural Networks. 2021 International Conference on INnovations in Intelligent SysTems and Applications (INISTA), Kocaeli, Turkey, pp. 1–6. <https://doi.org/10.1109/INISTA52262.2021.9548455>
- Wei, W., He, X., Bao, X., Wang, G., Luo, Q., Chen, L., Zhan, B., Lai, J., Jiang, J., Ye, L., & Liang, H. (2023). Application of deep learning algorithm in the recognition of cryptococcosis and talaromyces skin lesions. Mycoses, 66(8), 671–679. <https://doi.org/10.1111/myc.13598>
- Yotsu, R. R., Ding, Z., Hamm, J., & Blanton, R. E. (2023). Deep learning for AI-based diagnosis of skin-related neglected tropical diseases: A pilot study. PLoS Neglected Tropical Diseases, 17(8), e0011230. <https://doi.org/10.1371/journal.pntd.0011230>

METODOLOGÍA

Creación de conjuntos de datos de imágenes y entrenamiento de modelos



Fig. 2 Metodología seguida en el trabajo

RESULTADOS




Fig. 3 Matrices de confusión C1 (Cromoblastomycosis), C2 (Esporotricosis), C3 (Micotoma)




Fig. 4 Gráficas comparativas de precisión y accuracy

CONCLUSIONES

- El aprendizaje profundo, especialmente con VGG16, permite una clasificación efectiva de imágenes clínicas de micosis subcutáneas.
- El aumento de datos fue clave para compensar la escasez de imágenes originales.
- El uso de modelos preentrenados representa una estrategia prometedora para el desarrollo de herramientas clínicas, especialmente en contextos con recursos limitados; sin embargo, su efectividad en estos entornos aún debe ser validada experimentalmente.