

Uso de Redes Neuronales en el Análisis de Frotis de Células Sanguíneas Periféricas: una Revisión Sistemática de la Literatura

Use of Neural Networks in the Analysis of Peripheral Blood Cell Smears: A Systematic Review of the Literature.

Luis Francisco Pérez-Guillén ^a, Manuel de Jesús Matuz-Cruz ^b, Julia Yazmín Arana-Llanes ^c, Jorge Martín Guzmán-Albores ^d, María Soledad Peralta-González ^e, Noé González-Cárdenas ^f

Abstract:

The automation of the recognition and classification of blood cells makes it easier for physicians to diagnose different blood diseases by analysing their characteristics. Several researchers have developed algorithms using deep learning methods, specifically Neural Networks, in which some of these works have been complemented with the use of Support Vector Machines (although the main technique is Neural Networks) to improve the results, with the aim of classifying the different types of blood cells. For this reason, this research work presents a systematic review on the topic of the Use of Neural Networks in the Analysis of Peripheral Blood Cell Smears.

Keywords:

Neural networks, peripheral blood cell analysis, recognition, prediction, classification.

Resumen:

La automatización del reconocimiento y clasificación de las células sanguíneas facilita a los médicos el diagnóstico de distintas enfermedades de la sangre al analizar sus características. Diversas investigaciones han desarrollado algoritmos que emplean métodos de aprendizaje profundo, específicamente Redes Neuronales, en los que además algunos de estos trabajos se han complementado con el uso de Máquinas de Soporte Vectorial (a pesar de que la técnica principal sean las Redes Neuronales) para mejorar los resultados, con el objetivo de clasificar los diversos tipos de glóbulos sanguíneos. Es por ello, que este trabajo de investigación, se presenta una revisión sistemática sobre el tema de Uso de Redes Neuronales en el Análisis de Frotis de Células Sanguíneas Periféricas.

Palabras Clave:

Redes neuronales, análisis de frotis de células sanguíneas periféricas, reconocimiento, predicción, clasificación.

^a Tecnológico Nacional de México, Campus Tapachula, <https://orcid.org/0000-0001-9230-0251>, Email: al15510563@tapachula.tecnm.mx

^b Autor de Correspondencia, Tecnológico Nacional de México, Campus Tapachula, <https://orcid.org/0000-0002-9511-7572>, Email: mjmatuz@tapachula.tecnm.mx

^c Universidad Autónoma del Estado de Hidalgo, <https://orcid.org/0000-0002-4986-9765>, Email: julia_arana@uaeh.edu.mx

^d Tecnológico Nacional de México, Campus Tapachula, <https://orcid.org/0000-0002-3383-4605>, Email: yuek@hotmail.com

^e Tecnológico Nacional de México, Campus Tapachula, <https://orcid.org/0009-0008-2288-0455>, Email: msperaltagonzalez@gmail.com

^f Tecnológico Nacional de México, Campus Tapachula, <https://orcid.org/0009-0006-0531-9039>, Email: noe.gonzalez@tapachula.tecnm.mx

Introducción

Actualmente la población mundial se enfrenta al cáncer, siendo este un término que se emplea de manera genérica para describir un conjunto diverso de enfermedades que pueden afectar a cualquier parte del cuerpo; donde también se hace referencia a “tumores malignos” o “neoplasias malignas”. Su característica más definitoria es la rápida multiplicación de celular anormales que se propagan más allá de sus límites habituales y pueden invadir partes cercanas del cuerpo o diseminarse a otros órganos, en un proceso conocido como “metástasis”. Siendo la expansión de las metástasis la principal causa de muerte por esta enfermedad ^[1].

El frotis de sangre periférica constituye un examen que ofrece datos sobre la cantidad y forma de las células sanguíneas mediante una observación visual con el auxilio de un microscopio. Se utiliza como un complemento de la biometría hemática, la cual es fundamental para el diagnóstico de una amplia gama de enfermedades hematológicas. La muestra sanguínea se obtiene mediante una punción venosa, se deposita y se extiende sobre un portaobjetos, se tiñe con un colorante especial y se examina bajo el microscopio. Para una evaluación precisa del frotis sanguíneo, es importante considerar aspectos como la técnica de extendido, la tinción y la ubicación en el portaobjetos donde se realizará la evaluación. Este procedimiento permite obtener información detallada sobre la morfología de todos los tipos de células sanguíneas, una estimación aproximada del recuento de leucocitos y plaquetas, así como el recuento relativo de cada tipo de leucocitos al contar 100 células ^[2].

Las redes neuronales forman parte de la IA y representan un intento de simular el funcionamiento del cerebro humano a través de la construcción de sistemas que emplean elementos que se comportan de manera similar a las neuronas biológicas. La tarea principal de una red neuronal es generar un resultado específico cuando se le presenta un conjunto de datos de entrada. Asigna estos datos de entrada a diferentes categorías o grupos con la finalidad de conseguir la clasificación de patrones. El término "red neuronal" se deriva de su estructura, que consiste en una red de componentes interconectados. Estos componentes están inspirados en el funcionamiento de los sistemas nerviosos biológicos ^[3].

Cada año en México se detectan aproximadamente 195,500 casos de cáncer en sus diversas formas, según afirmó la Dra. Brenda Acosta Maldonado, quien es la jefa del Departamento de Hematología del Instituto Nacional de Cancerología (INCan) de la Secretaría de Salud. Además, señaló que el 46% de los pacientes fallece

debido a esta enfermedad. Durante una entrevista, señaló que la incidencia del cáncer en todas sus formas está en aumento, atribuyéndolo al incremento en la esperanza de vida y a la mejora en la detección de estas enfermedades, gracias a los avances tecnológicos que permiten un diagnóstico más preciso. Además, mencionó que anteriormente, en muchas ocasiones, los pacientes fallecían sin que sus familiares conocieran la causa, situación que ha cambiado con el tiempo. Existen dos categorías principales de cáncer: los tumores sólidos, como los que afectan a los senos y la próstata, y los que afectan la sangre, como la leucemia, el mieloma múltiple y el linfoma. En ambos casos, la detección temprana y la efectividad del tratamiento son factores cruciales para la supervivencia del paciente en la mayoría de los casos ^[4].

Por lo tanto, se presenta una revisión sistemática de la literatura (RSL) con el objetivo de explorar las implementaciones de las redes neuronales convolucionales, así como de las redes neuronales artificiales para la identificación de las diversas células sanguíneas, así como de la efectividad de implementar estas arquitecturas, todo esto con el objetivo de ofrecer un método alternativo utilizando IA.

Metodología

Con la finalidad de realizar esta RSL se consideraron criterios de elegibilidad, estrategia de búsqueda, selección de artículos y su extracción de información, todo esto descrito a continuación.

Criterios de elegibilidad

Para los propósitos de la revisión, es importante que los artículos estén escritos en inglés y publicados del año 2019 en adelante. Además, se definieron los siguientes criterios de elegibilidad:

- Artículos que incluyen la implementación de redes neuronales en la identificación de frotis de células sanguíneas periféricas.
- Artículos que incluyen la implementación de técnicas de visión artificial en la identificación de frotis de células sanguíneas periféricas.

Estrategias de búsqueda

Las fuentes de información consultadas fueron: *Google Scholar*, *IEEEExplore*, *ScienceDirect*, *SpringerLink*, *MDPI* y *arXiv*. La ejecución de las consultas se realizó entre enero de 2024 y abril de 2024.

Se crearon cadenas de búsqueda con diferentes combinaciones de palabras clave tomadas de tres grupos principales: enfermedad, tipo de implementación y técnica computacional (Tabla 1).

Tabla 1. Grupo de palabras clave de búsqueda.

| Grupos | Palabras claves |
|-------------------------|---|
| Objeto de estudio. | <i>Peripheral blood cells.</i> |
| Tipo de implementación. | <i>Recognition, Prediction, Classification.</i> |
| Técnica computacional. | <i>Convolutional neural networks, Artificial neural networks.</i> |

Las palabras clave dentro de cada grupo se conectaron usando el operador OR y los grupos con el operador AND; las dos combinaciones de grupos para las consultas de búsqueda fueron:

1. *Peripheral blood cells AND Recognition OR Classification AND Convolutional neural networks.*
2. *Peripheral blood cells AND Prediction OR Classification AND Artificial neural networks.*

Las cadenas de búsqueda fueron introducidas en los buscadores de las fuentes de consulta seleccionadas, obteniendo los resultados presentados en la Tabla 2.

Tabla 2. Total de artículos recuperados de las fuentes de consulta antes de aplicar las técnicas de cribado.

| No. de cadena | Google Académico | IEEExplore | Science Direct | Springer Link | MDPI | arXiv |
|---------------|------------------|------------|----------------|---------------|------|-------|
| 1 | 17,600 | 14,890 | 57,690 | 10,000 | 0 | 0 |
| 2 | 17,700 | 32,598 | 76,702 | 10,000 | 0 | 0 |

Selección de artículos

Se realizó un análisis de los trabajos obtenidos de cada búsqueda siguiendo el siguiente procedimiento: (1) se verificó la presencia de publicaciones duplicadas; (2) se evaluaron los criterios de exclusión basados en el título, resumen y palabras clave; y (3) se evaluaron los criterios de elegibilidad basados en el texto completo. Este proceso fue realizado en conjunto por los autores de este material de investigación.

Los artículos que no cumplían con los criterios de selección fueron descartados, mientras que aquellos que sí lo hacían fueron conservados para posterior análisis. En esta fase, se identificaron un total de 25 artículos relacionados con el tema de estudio.

Extracción de información

Después de realizar la selección final de los artículos se extrajeron diferentes datos: datos generales (autores e instituciones de origen, nombre de la revista o conferencia), datos del experimento (conjuntos de datos), datos relacionados con las arquitecturas empleadas (tipos de modelos de redes neuronales, características extraídas

de los datos del experimento o rendimiento) y datos relacionados con los resultados (hallazgos y conclusiones).

Resultados

Posteriormente a la lectura de los 25 trabajos seleccionados y a pesar de que en su mayoría presentan buenos resultados e información útil, se observó que 17 de ellos presentan de manera precisa, información altamente valiosa para cumplir el objetivo de esta investigación, como se mencionó en la sección introductoria, fue conocer las implementaciones de las redes neuronales convolucionales, así como de las redes neuronales artificiales para la identificación de las diversas células sanguíneas, así como de la efectividad de implementar estas arquitecturas, todo esto con el objetivo de ofrecer un método alternativo utilizando IA.

Estos trabajos fueron organizados mediante la siguiente tabla para conocerlos más a detalle.

Tabla 3. Resumen de artículo científicos destacados

| Artículo | Objetivo | Técnicas/Algoritmos | Resultados |
|----------|--|--|---|
| [5] | Propone un sistema para la clasificación automática de ocho grupos de células de sangre periférica con gran precisión mediante un enfoque de aprendizaje por transferencia que utiliza redes neuronales convolucionales. | Realizaron dos diseños basados en dos arquitecturas de redes neuronales convolucionales, VGG-16 e Inceptionv3. En el primer caso, las redes se utilizaron como extractores de características y estas características se utilizaron para entrenar un clasificador de máquina de soporte vectorial. En el segundo caso, las mismas redes se afinaron con el conjunto de datos para obtener dos modelos de extremo a extremo para la clasificación de las ocho clases de células sanguíneas. | En el primer caso, las precisiones de las pruebas experimentales obtenidas fueron del 86% y el 90% al extraer características con VGG-16 e Inceptionv3, respectivamente. Por otra parte, en el experimento de ajuste fino, se obtuvieron valores de precisión global del 96% y el 95% utilizando VGG-16 e Inceptionv3, respectivamente. |
| [6] | Propone un sistema automatizado asistido por ordenador con el método de aprendizaje profundo que puede identificar y localizar fácilmente los tipos de glóbulos blancos en imágenes de sangre. | AlexNet, VGG-16, GoogleNet, Resnet CNN fueron sido entrenadas y probadas con aprendizaje completo y aprendizaje por transferencia. | CNN Resnet50 y las arquitecturas entrenadas con Transfer Learning mostraron el mayor rendimiento en todas las células. Linfocitos: 99.52% de Accuracy. Monocitos: 98.40% de Accuracy. Basófilos: 98.48% de Accuracy. Eosinófilos: 96.16% de Accuracy. Neutrófilos: 95.04% de Accuracy. |
| [7] | Propone una comparación del enfoque tradicional de procesamiento de imágenes y los métodos de aprendizaje profundo para la clasificación de los glóbulos blancos. | Red neuronal convolucional desde cero y AlexNet fueron entrenadas y comprobadas. | Clasificador de red neuronal para las características elaboradas a mano: Precisión media del 99.8% (Accuracy = 95%, Sensitivity = 90% y Specificity = 98.6%) de CNN |

| | | | |
|------|--|--|---|
| | Además de utilizar enfoques de entrenamiento completo y aprendizaje por transferencia de redes neuronales convolucionales (CNN) para la clasificación. | | entrenamiento completo: Precisión en torno al 99% (<i>Accuracy</i> = 98.7%, <i>Sensitivity</i> = 99% y <i>Specificity</i> = 99.4%) |
| [8] | Propone un modelo basado en cápsulas diseñado para la multclasificación llamado BloodCaps, el cual precisa de un diverso y amplio espectro de células sanguíneas. | Red neuronal de cápsulas propio (BloodCaps), AlexNet, VGG-16, ResNet-18 e Inception V3. | El modelo propuesto fue superior en el <i>Accuracy</i> global frente a los demás modelos (99.3%) AlexNet = 81.5% de <i>Accuracy</i> . VGG-16 = 97.8% de <i>Accuracy</i> . ResNet-18 = 95.9% de <i>Accuracy</i> . Inception V3 = 98.4% de <i>Accuracy</i> . |
| [9] | Propone un método de aumento de datos y se adopta un método de remuestreo cuando se utiliza un método CNN. | Modelo de red neuronal propuesto, AlexNet, VGG-16, ResNet, MobileNet V1 e Inception V3. | El modelo propuesto fue superior en el <i>Accuracy</i> global frente a los demás modelos (97.6%) VGG-16 = 91.6% de <i>Accuracy</i> . ResNet = 93.2% de <i>Accuracy</i> . MobileNet V1 = 91.8% de <i>Accuracy</i> . Inception V3 = 94.1% de <i>Accuracy</i> . |
| [10] | Propone el primer modelo de aprendizaje profundo mediante redes neuronales convolucionales capaz de diferenciar glóbulos rojos infectados por malaria no solo de eritrocitos normales, sino también de eritrocitos con otros tipos de inclusiones. | VGG-16 mediante aprendizaje por transferencia. | El modelo propuesto obtuvo un <i>Accuracy</i> del 99.5% en la clasificación de parásitos de la malaria y otras inclusiones de glóbulos rojos. Este modelo también mostró valores de <i>Sensitivity</i> y <i>Specificity</i> del 100% y el 91.7%, respectivamente, al momento de clasificar un frotis completo como infectado o no infectado. |
| [11] | Propone un método de redes neuronales convolucionales deformables optimizadas ponderadas de dos módulos (TWO-DCNN) para la clasificación de globulos blancos. Este algoritmo propuesto se caracteriza por un aprendizaje por transferencia de dos módulos y capas convolucionales deformables (DC) para mejorar la robustez. | Modelo propuesto, VGG-16, VGG-19, Inception V3, ResNet-50, máquina de soporte vectorial (SVM), perceptrón multicapa (MLP), árbol de decisión (DT) y bosque aleatorio (RF). | El modelo propuesto (TWO-DCNN) obtuvo el mejor rendimiento con <i>Precision</i> del 95.7%, 94.5% y 91.6%, <i>Recall</i> del 95.7%, 94.5% y 91.6%, unas puntuaciones F1 del 95.7%, 94.5% y 91.6%, y un área bajo la curva (AUC) del 0.98, 0.97 y 0.95 para los conjuntos de datos de baja resolución y ruidosos (ambos no revelados) y el conjunto de datos BCCD, respectivamente. |
| [12] | Este trabajo investiga las operaciones de transformación de imágenes y las redes generativas adversariales (GAN) para el aumento de datos y las redes neuronales profundas más avanzadas para la | VGG-16, ResNet y DenseNet. | DenseNet-169, arroja un resultado del 98.8% de <i>Precision</i> . Adicionalmente, los autores observaron que el enfoque propuesto supera a otros métodos que se basan en un sofisticado procesamiento de |

| | | | |
|------|---|---|---|
| | clasificación de los glóbulos blancos en cinco tipos. | | imágenes y en la ingeniería manual de características. |
| [13] | Propone un sistema basado en aprendizaje profundo para predecir el diagnóstico de leucemia aguda utilizando imágenes de células sanguíneas y un sistema de clasificación secuencial CNN: ALNet | VGG-16, ResNet-101, DenseNet-121, SENet-154 y AI-Net. | ALNet proporcionó la predicción diagnóstica correcta de todos los pacientes con leucemia promielocítica y mieloide. Para la predicción de leucemia mieloide se obtuvieron valores de <i>Sensitivity</i> , <i>Specificity</i> y <i>Precision</i> del 100%, 92.3% y 93.7%, respectivamente. En cuanto a la leucemia linfocítica, se obtuvo un valor de <i>Sensitivity</i> del 89% y unos valores de <i>Specificity</i> y <i>precision</i> del 100%. |
| [14] | Propone un modelo que no necesite preprocesamiento y pueda realizar una clasificación satisfactoria en conjuntos de datos pequeños de glóbulos blancos como una alternativa para el aprendizaje profundo y el análisis de datos médicos cuando el tamaño de la muestra es limitado. | Red neuronal de cápsulas propio, Inception-ResNET V2, Inception V3, ResNet-50 y VGG-19. | Las redes neuronales convolucionales y los modelos de aprendizaje por transferencia empleados en esta investigación sufrieron de sobreajuste, mientras que las redes de cápsulas aprendieron bien los datos de entrenamiento y lograron una alta valor de <i>Accuracy</i> en los datos de prueba (96.86%) superando las dificultades de realizar un preprocesamiento y necesitar una muestra de tamaño grande. |
| [15] | Propone un estudio comparativo de la extracción de características utilizando dos enfoques para la clasificación de los leucocitos. | Como primer enfoque, la extracción de características utilizando el método tradicional de procesamiento de imágenes y en el segundo enfoque el uso de AlexNet como generador de características. Además de utilizar la red neuronal para clasificar los glóbulos blancos. | Los hallazgos indican que el rendimiento de la clasificación es ligeramente superior al emplear características extraídas mediante la metodología de red neuronal convolucional en contraposición al enfoque convencional de procesamiento de imágenes. Se logró un promedio del 99% en los valores de <i>Precision</i> y <i>Sensitivity</i> en la clasificación de los glóbulos blancos. |
| [16] | Propone un modelo de fusión de CNN y RNN propuesto con análisis de correlación canónica. | CNN: VGG-16, Inception V3, ResNet-50, Xception. RNN: LSTM. Optimizadores: SGD y RMSProp. | El modelo propuesto determina una mayor precisión en comparación con otras técnicas de clasificación de células sanguíneas del estado del arte. Destacando las siguientes configuraciones del modelo de fusión: VGG-16 + LSTM = 89.85% de <i>Accuracy</i> . |

| | | | |
|------|---|---|--|
| | | | Inception V3 + LSTM = 91.06% de <i>Accuracy</i> . ResNet50 + LSTM = 93.16% de <i>Accuracy</i> . Xception + LSTM = 95.89% de <i>Accuracy</i> . |
| [17] | Propone un algoritmo que emplea un enfoque de aprendizaje profundo para la segmentación y clasificación mediante dos etapas <i>pipelining</i> que consisten en la segmentación semántica y la clasificación basada en el aprendizaje de transferencia. | DeepLabv3+ y AlexNet. | El modelo propuesto alcanzó un valor del 98.42% de <i>Precision</i> de media en la localización de leucocitos y una clasificación con 98.87 % de <i>Precision</i> en comparación con los métodos existentes. Linfocitos: 99.10% de <i>Accuracy</i> . Monocitos: 94.55% de <i>Accuracy</i> . Basófilos: 99.60% de <i>Accuracy</i> . Eosinófilos: 99.42% de <i>Accuracy</i> . Neutrófilos: 99.45% de <i>Accuracy</i> . |
| [18] | Propone un modelo de CNN híbrido basado en aprendizaje profundo para la clasificación de glóbulos blancos (eosinófilos, linfocitos, monocitos y neutrófilos). | Alexnet, Googlenet y máquina de soporte vectorial. | El modelo híbrido AlexnetGooglenet-SVM proporciona mayor precisión que los Alexnet y Googlenet preentrenados por separado. Logrando valores de <i>Precision</i> y de puntuación F1 del 99.73%, 0.99 y 98.23%, 0.98 para los conjuntos de datos de Kaggle y LISC, respectivamente. |
| [19] | Propone un innovador método de tres fases que abarca la segmentación de los eritrocitos, su posterior recorte y enmascaramiento, y finalmente su clasificación como infectados o no por malaria. | Red neuronal de segmentación y una red neuronal convolucional desde cero. | La segmentación logró un valor de 93.72% de <i>Precision</i> en el conjunto de pruebas, mientras que el valor de <i>Specificity</i> para identificar la malaria en glóbulos rojos fue del 87.04%. |
| [20] | Propone un modelo para el reconocimiento y clasificación de imágenes de células sanguíneas en 5 tipos (eosinófilos, basófilos, linfocitos, monocitos y neutrófilos) periféricas utilizando una combinación del algoritmo Salp Swarm y el algoritmo Cat Swarm Optimization (SSPSO) basado en redes neuronales convolucionales optimizadas (SSPSO-CNN). | Salp Swarm, SSPSO y VGG-19. | El modelo propuesto SSPSO-CNN entrenado con las funciones de VGG-19 obtuvo un valor de 98% de <i>Accuracy</i> en promedio. Linfocitos: 97.43% de <i>Accuracy</i> . Monocitos: 98.68% de <i>Accuracy</i> . Basófilos: 97.65% de <i>Accuracy</i> . Eosinófilos: 98.87% de <i>Accuracy</i> . Neutrófilos: 97.78% de <i>Accuracy</i> . |
| [21] | Propone un método eficiente para el reconocimiento automático de glóbulos blancos en imágenes de sangre periférica y | Algoritmo Mask RCNN y modelo CNN propuesto. | Los hallazgos indican que el modelo propuesto fue prometedor y demostró su eficacia, potencia y velocidad en comparación con |

| | |
|---|--|
| médula ósea basado en aprendizaje profundo. | los métodos más avanzados. Además de su <i>Accuracy</i> del 95.73%, el método propuesto proporcionó predicciones rápidas (menos de 1 segundo). |
|---|--|

Conclusiones

En conclusión, durante esta investigación se logró identificar gran cantidad de artículos relacionados con el tema de interés de la RSL, cabe resaltar que en sus características cada trabajo demuestra que es un área con gran complejidad, debido a que el tratar con imágenes médicas representa un reto enorme al extraer e identificar las características necesarias para lograr buenos resultados en la experimentación.

De manera concreta, los principales hallazgos de la RSL fueron los siguientes:

En lo que respecta a la evaluación de los resultados, se suelen utilizar métricas de la matriz de confusión de las que se emplearon: *Accuracy*, *Precision*, *Recall*, *Specificity* y *F1 Score*; obteniendo resultados prometedores en un gran número de investigaciones con los algoritmos VGG, AlexNet y las modelos de CNN configurados desde cero como propuesta propia, donde fueron los mejores no solo en sus resultados, sino que además demostraron que son algoritmos eficientes al trabajar con los frotis de células sanguíneas periféricas.

En este estudio, se presentan metodologías innovadoras para la clasificación automatizada de glóbulos blancos mediante el uso de redes neuronales convolucionales (CNN). Además de que algunas investigaciones complementan este tipo de técnicas con el uso de Máquinas de Soporte Vectorial (a pesar de que la técnica principal utilizada sean las Redes Neuronales) para mejorar los resultados. A través de un proceso conformado de diversas etapas, se han logrado clasificaciones precisas de hasta seis tipos de glóbulos blancos, incluyendo linfocitos, monocitos, neutrófilos, eosinófilos, basófilos y células anormales. Con la implementación de CNNs entrenadas con conjuntos de datos extensos muestra un rendimiento excepcional, con una precisión promedio del 99%. Además, se aborda específicamente la detección de malaria en glóbulos rojos, utilizando una metodología que alcanza una precisión global del 93.72% y una especificidad del 87.04%. Estos enfoques no solo proporcionan una herramienta precisa y eficiente para el diagnóstico de enfermedades sanguíneas, sino que también resalta el potencial del aprendizaje profundo en la patología digital.

Con esta investigación, se cumple el objetivo de explorar las implementaciones de las redes neuronales convolucionales, así como de las redes neuronales artificiales para la identificación de las diversas células sanguíneas, así como de la efectividad de implementar estas arquitecturas, todo esto con el objetivo de ofrecer una perspectiva de métodos alternativos de diagnóstico

utilizando IA. Este análisis describe el estado actual y el que podrían tomar futuras investigaciones al considerar mejoras en este campo, así como de la ampliación del uso de las redes neuronales en el diagnóstico clínico.

Referencias

- [1] *Cáncer*. (s/f). Who.int. Recuperado el 15 de abril de 2024, de <https://www.who.int/es/news-room/fact-sheets/detail/cancer>
- [2] del Carmen Tarín Arzaga, L. (2016). Frotis de la sangre periférica en las enfermedades más frecuentes. En J. Pérez & D. Almaguer (Eds.), *Hematología. La sangre y sus enfermedades*. McGraw-Hill Education.
- [3] Picton, P. (1994). What is a neural network? En *Introduction to Neural Networks* (pp. 1–12). Macmillan Education UK.
- [4] SALUD. (s/f). 294. *México registra al año más de 195 mil casos de cáncer: Secretaría de Salud*. Gobierno de México. Recuperado el 15 de abril de 2024, de <https://www.gob.mx/salud/prensa/294-mexico-registra-al-ano-mas-de-195-mil-casos-de-cancer-secretaria-de-salud>
- [5] Acevedo, A., Alférez, S., Merino, A., Puigvi, L., & Rodellar, J. (2019). RECOGNITION OF PERIPHERAL BLOOD CELL IMAGES USING CONVOLUTIONAL NEURAL NETWORKS. *Computer Methods and Programs in Biomedicine*, 105020. doi:10.1016/j.cmpb.2019.105020
- [6] Kutlu, H., Avci, E., & Özyurt, F. (2019). White Blood Cells Detection and Classification Based on Regional Convolutional Neural Networks. *Medical Hypotheses*, 109472. doi:10.1016/j.mehy.2019.109472
- [7] Hegde, R. B., Prasad, K., Hebbar, H., & Singh, B. M. K. (2019). Comparison of traditional image processing and deep learning approaches for classification of white blood cells in peripheral blood smear images. *Biocybernetics and Biomedical Engineering*. doi:10.1016/j.bbe.2019.01.005
- [8] Long, F., Peng, J.-J., Song, W., Xia, X., & Sang, J. (2021). BloodCaps: A capsule network based model for the multiclassification of human peripheral blood cells. *Computer Methods and Programs in Biomedicine*, 202, 105972. doi:10.1016/j.cmpb.2021.105972
- [9] Wang, Y., & Cao, Y. (2019). Human Peripheral Blood Leukocyte Classification Method Based on Convolutional Neural Network and Data Augmentation. *Medical Physics*. doi:10.1002/mp.13904
- [10] Molina, A., Rodellar, J., Boldú, L., Acevedo, A., Alférez, S., & Merino, A. (2021). Automatic identification of malaria and other red blood cell inclusions using convolutional neural networks. *Computers in Biology and Medicine*, 136, 104680. doi:10.1016/j.compbiomed.2021.104680
- [11] Yao, X., Sun, K., Bu, X., Zhao, C., & Jin, Y. (2021). Classification of white blood cells using weighted optimized deformable convolutional neural networks. *Artificial Cells, Nanomedicine, and Biotechnology*, 49(1), 147–155. doi:10.1080/21691401.2021.1879823
- [12] Almezghwi, K., & Serte, S. (2020). Improved classification of white blood cells with the generative adversarial network and deep convolutional neural network. *Computational Intelligence and Neuroscience*, 2020, 1–12. <https://doi.org/10.1155/2020/6490479>
- [13] Boldú, L., Merino, A., Acevedo, A., Molina, A., & Rodellar, J. (2021). A deep learning model (ALNet) for the diagnosis of acute leukaemia lineage using peripheral blood cell images. *Computer Methods and Programs in Biomedicine*, 202, 105999. doi:10.1016/j.cmpb.2021.105999
- [14] Baydilli, Y. Y., & Atila, Ü. (2020). Classification of white blood cells using capsule networks. *Computerized Medical Imaging and Graphics*, 101699. doi:10.1016/j.compmedimag.2020.101699
- [15] Hegde, R. B., Prasad, K., Hebbar, H., & Singh, B. M. K. (2019). Feature extraction using traditional image processing and convolutional neural network methods to classify white blood cells: a study. *Australasian Physical & Engineering Sciences in Medicine*, 42(2), 627–638. doi:10.1007/s13246-019-00742-9
- [16] Patil, A. M., Patil, M. D., & Birajdar, G. K. (2020). White Blood Cells Image Classification using Deep Learning with Canonical Correlation Analysis. *IRBM*. doi:10.1016/j.irbm.2020.08.005
- [17] Reena, M. R., & Ameer, P. M. (2020). Localization and recognition of leukocytes in peripheral blood: A deep learning approach. *Computers in Biology and Medicine*, 126, 104034. doi:10.1016/j.compbiomed.2020.104034
- [18] Çınar, A., & Tuncer, S. A. (2021). Classification of lymphocytes, monocytes, eosinophils, and neutrophils on white blood cells using hybrid Alexnet-GoogleNet-SVM. *SN Applied Sciences*, 3(4). doi:10.1007/s42452-021-04485-9
- [19] Delgado-Ortet, M., Molina, A., Alférez, S., Rodellar, J., & Merino, A. (2020). A deep learning approach for segmentation of red blood cell images and malaria detection. *Entropy (Basel, Switzerland)*, 22(6), 657. <https://doi.org/10.3390/e22060657>
- [20] Kumar, R., Joshi, S., & Dwivedi, A. (2020). CNN-SSPSO: A Hybrid and Optimized CNN approach for peripheral blood cell image recognition and classification. *International Journal of Pattern Recognition and Artificial Intelligence*. doi:10.1142/s0218001421570044
- [21] Khouani, A., El Habib Daho, M., Mahmoudi, S. A., Chikh, M. A., & Benzineb, B. (2020). Automated recognition of white blood cells using deep learning. *Biomedical Engineering Letters*. doi:10.1007/s13534-020-00168-3