

DIAGNÓSTICO ASISTIDO POR INTELIGENCIA ARTIFICIAL DE APRENDIZAJE PROFUNDO PARA EL TAMIZAJE AUTOMÁTICO DE ANORMALIDADES DE FONDO DE OJO DE MÚLTIPLES PATOLOGÍAS (DIA-FACMED)

Esther Mahuina Campos-Castolo, Alejandro Alayola Sansores, Orlando Cerón Solís, Dania Nimbe Lima Sánchez, Moisés Argueta Santillán

Departamento de Informática Biomédica, Facultad de Medicina, UNAM, México.
dibfm@unam.mx

RESUMEN

Las alteraciones en retina son un problema de salud pública. Un método que se ha investigado a últimas fechas es el uso de la detección automática por medio de la Inteligencia artificial, sin embargo, hasta el momento aún no existe un algoritmo validado en población mexicana ni que detecte múltiples patologías al mismo tiempo.

Describimos la implementación de un algoritmo de inteligencia artificial que usa una red neuronal para este propósito y mostramos los resultados posteriores al entrenamiento.

Finalmente discutimos y analizamos los resultados y obtenemos las conclusiones finales de este estudio.

Palabras clave. Retina, Deep Learning, Inteligencia Artificial

ABSTRACT

Alterations in the retina are a public health problem. A method that has been investigated lately is the use of automatic detection using artificial intelligence, however, until now there is not yet an algorithm validated in the Mexican population or that it detects multiple pathologies at the same time.

We describe the implementation of an artificial intelligence algorithm that uses a neural network for this purpose, and we show the results after the training.

Finally, we discuss and analyse the results and obtain the conclusions of this study.

Keywords. Retinal, Deep Learning, Artificial Intelligence.

1. INTRODUCCIÓN

Las patologías de la vista, en especial las relacionadas con la retina son patologías muy extendidas entre la población mexicana, sobre todo cuando están relacionadas con otras patologías como lo son la diabetes y la hipertensión (1) y sus síntomas suelen pasar desapercibidos la mayoría de las veces como para que nos alerten a tiempo de su existencia.

El interior del ojo es una zona muy sensible por lo que estas patologías en el fondo del ojo están asociadas en algunas ocasiones a enfermedades sistemáticas como diabetes o cáncer, por lo que no sólo hablamos de un problema de la vista sino de la salud de todo el cuerpo.

El diagnóstico no siempre está disponible, debido a la enorme demanda y la escasez de estos especialistas. Situación que empeorará observando que estas patologías son más comunes a mayores edades y la tendencia de la población mexicana a envejecer.

Ahora ya concretando las consideraciones clínicas de este trabajo establecemos las patologías que nos interesan, esta decisión es en base a la cantidad de casos clínicos que contamos, la utilidad de estudiarlas. Son patologías que como decíamos anteriormente pueden pasar desapercibidas en etapas tempranas, se pueden deducir de imágenes de fondo de ojo a tiempo y representan un problema común en la salud de la población mexicana.

2. TEORÍA

Las patologías que nos interesan en este proyecto de investigación son retinopatía diabética, retinopatía hipertensiva y glaucoma. Vamos a automatizar el proceso de aprendizaje, de esta manera la máquina irá aprendiendo con el tiempo y suficientes ejemplos las características necesarias a tener en cuenta para hacer una inferencia fidedigna. Las herramientas de Inteligencia Artificial más comunes y eficaces para detectar patrones son las redes neuronales y en concreto a lo que refiere a las imágenes son las redes neuronales convolucionales.

Las redes neuronales convolucionales funcionan de una forma similar a como funciona nuestra propia visión, imitando a la corteza visual del ojo humano, activándose según las características que pueda apreciar, empezando de las formas más básicas hacia unas más complejas. De esta manera tenemos una jerarquía de representaciones de la imagen por medio de la red neuronal (1) especialmente útil en el caso de análisis de imágenes y extracción de características relevantes. Las patologías que analizamos presentan lesiones o alteraciones que con el equipo debido pueden ser detectadas usando algún tipo de Inteligencia Artificial (2). Las Redes neuronales convolucionales permiten el análisis, clasificación, regresión, etc. de datos de datos de muchas dimensiones sin ingeniería de datos previa. (3). Las redes neuronales convolucionales son modelos de Deep learning capaces de detectar características complejas de una imagen (1).


Sin embargo, como vemos en las implementaciones que se han hecho de las redes neuronales convolucionales, llega un punto en que mayor cantidad de nodos o capas no hacen un cambio significativo (4). Las redes neuronales de aprendizaje profundo funcionan

de forma más eficiente con la función de activación rectificador lineal ReLu, que con otras más tradicionales (5), otras variaciones del rectificador lineal suelen mejorar la eficiencia que se ajusten según el data set pero presentar problemas de sobreajuste.

3. PARTE EXPERIMENTAL

El objetivo del estudio es desarrollar, validar, estandarizar y evaluar la utilidad diagnóstica de un sistema de tamizaje de alteraciones de fondo de ojo en múltiples patologías basado en un algoritmo de inteligencia artificial de aprendizaje profundo para evaluar alteraciones de fondo de ojo en múltiples patologías.

Materiales y Métodos: Se realizó un estudio observacional, transversal multi-céntrico de prueba diagnóstica para determinar la sensibilidad y especificidad de un sistema de aprendizaje basado en dos modelos de Red Neuronal Artificial de aprendizaje profundo. Se utilizaron fotografías digitales de fondo de ojo tomadas con una cámara no midriática, todas las imágenes fueron de población mexicana, se descartaron las no valorables. El diagnóstico para establecer el Gold-Estándar de las fotos fue realizado por un médico oftalmólogo retinólogo. Se seleccionaron finalmente 1387 fotos clasificadas por diagnóstico de excavación de nervio óptico, adelgazamiento de retina, degeneración macular, retinopatía diabética, retinopatía hipertensiva y retina normal.



Gráfica 1. Curva COR para detección entre sanos y enfermos

Tabla 1. Diagnóstico realizado por el algoritmo de IA Vs. Diagnóstico del Oftalmólogo retinólogo

Diagnóstico del Algoritmo	Diagnóstico del médico				
	Sanos	Glaucoma	Hipertensiva	Diabética	Total
Sanos	459	105	2	111	677
Glaucoma	50	595	0	84	729
Hipertensiva	39	5	442	101	587
Diabético	411	254	22	592	1279
Total	959	959	466	888	3272

RESULTADOS: El algoritmo fue basado en redes neuronales convolucionales, con las cuales se evaluaron 1332 imágenes que fueron pre procesadas modificando la posición para obtener un total de 3490 imágenes. El diagnóstico realizado por el algoritmo y el médico se presentan en la Tabla 1. Los resultados para detectar a sujetos sanos la sensibilidad fue de .47 y la especificidad de 0.906, para detección de glaucoma Sensibilidad=0.214 y la Especificidad =0.731, para detectar retinopatía hipertensiva la Sensibilidad=0.94 y la Especificidad=0.94 y finalmente para retinopatía diabética la Sensibilidad=0.67 y la Especificidad=0.71, Kappa=.513. Se muestra la Curva ROC con los datos de Sensibilidad y Especificidad ya comentados en la Gráfica 1.

4. CONCLUSIONES

La red con las imágenes de retinopatía hipertensiva parece tener un mejor desempeño que el resto que oscilan en números similares, pero eso tiene una explicación: Si bien las imágenes de entrenamiento, validación y testeo son diferentes, las pocas imágenes existentes en esta categoría las imágenes modificadas si bien diferentes tienen el mismo origen en el caso de retinopatía hipertensiva lo que explica el sobreajuste. Los datos indican que la mayor incidencia de falsos positivos (buscando patologías) se da con la retinopatía diabética y de forma más marcada retinopatía diabética que diagnóstica como ausentes de patología.

Parece haber cierta ambigüedad entre los ojos sanos y los ojos de retinopatía diabética. Con esto quiero decir que a la red neuronal le cuesta diferenciar entre ojos sanos y los afectados con retinopatía diabética. En el caso de retinopatía diabética como vemos en la matriz de confusión o en la curva ROC, hubo mucha dificultad en detectarla y la confundía principalmente con la categoría de ojos sanos. Esto puede deberse a dos razones principalmente: La primera es que la razón a la que puede deberse es que los pacientes de la base de datos de donde proceden las imágenes podrían presentar en un ojo las lesiones indicativas de alguna variedad de retinopatía diabética, pero en el otro no, a pesar de lo cual ambas imágenes de los ojos iban a esta categoría. Sumado al diagnóstico previo de diabetes en los pacientes, éstos podrían tener mayor sesgo a ser detectados con retinopatía diabética, aunque su fondo de ojo tenga una apariencia de sano.

La segunda posibilidad es que, dada la gran variedad de variantes, simplemente la red no haya estado suficientemente refinada para detectar las características más sutiles como en otras categorías que tendrían características más claras. La sensibilidad para detectar pacientes sanos contra enfermos es buena, sin embargo, es necesario mejorar la exactitud para múltiples diagnósticos.

5. REFERENCIAS

- [1] Bishop M. Pattern Recognition and Machine Learning: Springer; 2006.
- [2] Krizhevsky I. Imagenet classification with deep convolutional neural networks, Advances in neural information processing systems. Proceeding. 2012.

- [3] Deep-learning based multiclass retinal fluid segmentation and detection in optical coherence tomography images using a fully convolutional neural network. Elsevier. 2019.
- [4] Goodfellow . Deep learning: MIT press Cambridge; 2016.
- [5] Ameri A, Akhaee MA, Scheme E, Englehart. Regression convolutional neural network for improved simultaneous EMG control. Journal of Neural Engineering. 2018.