

DEEP LEARNING GLAUCOMA DIAGNOSIS AID

**Civit, Javier; Amaya, Isabel; Luna, Francisco; Duran, Lourdes; Civit, Antón;
Linares-Barranco, Alejandro; Vicente, Saturnino**

Grupo de Robótica y Tecnología de Computadores
Departamento de Arquitectura y Tecnología de Computadores. EPS, Universidad
de Sevilla.

*E-mail: javi.civit@gmail.com

RESUMEN

El glaucoma es una de las principales causas de ceguera. Cambia la morfología del nervio óptico. La copa es la región central del disco óptico. El CDR (relación del diámetro de la copa y el disco) es un indicador del estado de la enfermedad. Un CDR normal se encuentra entre 0.3 y 0.4. A mayor CDR Glaucoma más avanzado. En este trabajo se pretende demostrar la viabilidad de los algoritmos en los que la forma del disco y la copa son aproximadamente círculos. En estos casos el número de parámetros es mucho menor y, al menos, en nuestras pruebas iniciales la aproximación es más realista que con las formas originales para su implementación en aprendizaje profundo.

PALABRAS CLAVE

Glaucoma, Deep Learning, Ayuda al Diagnóstico, Aproximación por círculos.

ABSTRACT

Glaucoma is one of the main causes of blindness. It changes the morphology of the optic nerve. The cup is the central region of the optical disc. The CDR (ratio of the diameter of the cup and disc) is an indicator of the state of the disease. A normal CDR is between 0.3 and 0.4. A higher CDR more advanced glaucoma. In this work we try to demonstrate the viability of algorithms in which the shape of the disc and the cup are approximately circles. In these cases, the number of parameters is much lower and, at least, in our initial tests the approach is sometimes more realistic than with the original forms for a Deep learning implementation.

KEYWORDS

Glaucoma, Deep Learning, Diagnostic Aid, Circle Approximation.

INTRODUCCIÓN Y OBJETIVOS

En este trabajo estudiaremos distintas posibilidades para aproximar las formas del disco y la copa óptica por círculos. Más tarde veremos la influencia que tienen estas aproximaciones en la detección mediante Deep learning del disco óptico y lo compararemos con una aproximación con detección directa.

METODOLOGÍA

Utilizaremos inicialmente el método de detección de disco y copa propuesto en [1]. Este método emplea la red de convolución-deconvolución U-Net [2] que es ampliamente empleada en la detección de imágenes médicas.

El conjunto de datos empleado en nuestras pruebas es RIM-ONE v3.

Inicialmente comenzamos realizando la segmentación del disco. Para ello empleamos nuestro tutorial en Google collaboratory [3]. Un ejemplo de los resultados de la segmentación se muestra en la Figura 1.




Figura 1. Segmentación del Disco.

Veremos ahora las distintas posibilidades de aproximar la máscara (ground truth) de la figura por un círculo. En principio planteamos tres posibles métodos:

- Detectar el borde de la máscara y ajustar un círculo a dicha curva.
- Detectar la caja contenedora (Bounding Box) de la máscara y aproximar la misma utilizando el centro de la caja como centro y la media de los semilados como radio.
- Detectar el centroide y el área de la máscara y emplear como centro el centroide y como radio la raíz cuadrada del área dividido por pi.

La evaluación de las diferentes alternativas la realizaremos evaluando los coeficientes de intersección sobre unión (Dice) de las distintas aproximaciones con la máscara real. De los métodos propuestos se seleccionará el que proporcione mejores ajustes y con él se entrenará de nuevo el sistema de segmentación para comparar los resultados con la versión inicial.

Ha de tenerse en cuenta que la información necesaria para este caso es mucho menor que para el sistema original al solo tener que obtener el centro y el radio de cada disco o copa.

RESULTADOS Y DISCUSIÓN

Para ajustar la aproximación circular a la curva externa de la máscara detectamos la misma empleando el módulo `segmentation` de `scikit-image` [4] para después emplear RANSAC [5] para aproximar el modelo del círculo. En este caso sobre el conjunto de imágenes se logra un valor medio del coeficiente Dice de un 93% con una desviación típica de 4.7 para los discos ópticos.

En el caso del método del centroide empleamos el módulo `measure` de `scikit-image` para obtener las propiedades de la región correspondiente a la máscara. De estas propiedades utilizamos el centroide y el área. Empleando este método obtenemos un valor medio del coeficiente Dice de un 96% con una desviación típica de 1.6 para los discos ópticos.

Para el caso de las cajas contenedoras empleamos también el módulo `measure` de `scikit-image`. En este caso nos quedamos con los datos de la caja que contiene a la máscara. Con este método obtenemos valores del coeficiente prácticamente idénticos a los obtenidos utilizando el centroide.

En la Figura 2 se muestran para la imagen en que el ajuste es mejor y peor los ajustes de los círculos por el método del borde, el del centroide y el de la caja contenedora.

Como última fase procedemos a utilizar los datos de los círculos correspondientes a los discos como máscaras en nuestro notebook en Google colab. Empleamos los discos calculados empleando el método de las regiones contenedoras.




Figura 2. Ajuste de Círculos.

En la Figura 3 se muestra un ejemplo de entrenamiento realizado con máscaras circulares.




Figura 3. Imágenes ajustadas con círculos.

CONCLUSIONES

Puede verse que la aproximación mediante círculos reduce, en gran medida el número de parámetros necesarios para representar el círculo y la copa perdiendo poca información útil en esta transformación. Esto nos puede permitir enfocar la segmentación empleando modelos más sencillos.

AGRADECIMIENTOS

This work was partially supported by the NPP project funded by SAIT (2015-2018) and by the Spanish government grant (with support from the European Regional Development Fund) COFNET (TEC2016-77785-P).

The cloud environment for the project was supported by Google GCP research credits program.

REFERENCIAS BIBLIOGRÁFICAS

- [1] Sevastopolsky A. (2017). Optic disc and cup segmentation methods for glaucoma detection with modification of U-Net convolutional neural network. *Pattern Recognition and Image Analysis*, 27(3), 618–624.
- [2] Ronneberger, O., Fischer, P., y Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *International Conference on Medical image computing and computer-assisted intervention*. arXiv:1505.04597v1
- [3] Civit-Masot, J., Petkevičius, L., y Civit, A. (2018). The Tensorflow/Keras tutorial on image segmentation. Google colab, Google. Recuperado de: <https://bit.ly/2zLAzv0>
- [4] Van der Walt, S., Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., ... Yu, T. (2014). Scikit-image: image processing in Python. *PeerJ*, 2, e453.
- [5] Derpanis, Konstantinos G. (2010). Overview of the RANSAC Algorithm. *Image Rochester NY*, 4.1, 2-3.