

Sistema open source para generar imágenes de entrenamiento para uso en detección de vasos sanguíneos: resultados preliminares

Roger Chiu Coutiño

Tecnológico Nacional de México campus León División de Estudios de Posgrado e Investigación León, Gto.

México

m22240201@leon.tecnm.mx

David Guitierrez Hernandez

Tecnológico Nacional de México campus León División de Estudios de Posgrado e Investigación León, Gto.

México davidasael.gutierrez@leon.tecnm.mx

Roger Chiu Zarate

Universidad de Guadalajara

Departamento de Ciencias Exactas y Tecnología, Centro Universitario de los Lagos

Lagos de Moreno, Jal, México

rchiu@culagos.udg.mx

Miguel Salvador Soriano Garcia

Universidad de Guadalajara

Departamento de Ciencias Exactas y Tecnología, Centro Universitario de los Lagos Lagos de Moreno, Jal, México miguel.soriano@alumnos.udg.mx

Carlos Lino Ramirez

Tecnológico Nacional de México campus León División de Estudios de Posgrado e Investigación León, Gto.

México

carlos.lino@leon.tecnm.mx

Victor Zamudio Rodriguez

Tecnológico Nacional de México campus León División de Estudios de Posgrado e Investigación León, Gto. México

victormanuel.zamudio@leon.tecnm.mx

Resumen—

La visualización de vasos sanguíneos en combinación con la medición del flujo sanguíneo, son tareas básicas para evaluar la salud e integridad biológica de los tejidos. Varias técnicas han sido propuestas para lograr estas tareas con éxito, sin embargo dichas técnicas pueden llegar a ser molestas o invasivas. En consecuencia a esto, la óptica ha propuesto algunas soluciones para la visualización de vasculatura, encontrándose con problemas para visualizar vasculatura profunda, por esta razón, las técnicas ópticas se han combinado con inteligencia artificial para lograr una mejora en la visualización de vasculatura profunda. Sin embargo uno de los mayores problemas al entrenar modelos de deep learning se presenta en el conjunto de entrenamiento. Debido a esto, en este artículo proponemos un sistema open source para la generación de imágenes de entrenamiento para modelos de deep learning enfocados al reconocimiento de estructuras en medios altamente dispersivos.

Index Terms—reconocimiento de estructuras, medios altamente dispersivos, deep learning, redes neuronales convolucionales.

I. INTRODUCCIÓN

El sistema cardiovascular se encarga de la transportación de sangre oxigenada a través del cuerpo humano, permitiendo a los demás órganos y tejidos realizar su función principal. El sistema cardiovascular está compuesto por el corazón, el cual es el encargado de bombear sangre oxigenada a través de la aorta, arterias, arteriolas y capilares hacia los órganos del cuerpo. Los tejidos de los órganos extraen oxígeno y nutrientes de la sangre en los capilares y la sangre desoxigenada se devuelve al corazón por medio de las vénulas, las venas y las venas cavas [1].

La visualización de vasos sanguíneos en combinación con la medición del flujo sanguíneo, son tareas básicas para evaluar la salud e integridad biológica de los tejidos. Debido a esto, en este trabajo presentamos un sistema abierto de bajo costo que nos permita generar imágenes de entrenamiento para modelos de deep learning enfocados a reconocer objetos a través de medios altamente dispersivos. Donde proponemos el uso de difusores caracterizados con las propiedades ópticas de dispersión de la piel, permitiéndonos entrenar modelos capaces de aprender a visualizar estructuras como lo pudiese ser la vasculatura profunda aún en medios con alto esparcimiento.

II. ANTECEDENTES

Existen diferentes maneras de poder observar el sistema circulatorio, una de ellas es la de angiografía, el cual es un estudio por el cual se pueden observar las arterias en las manos, los brazos, los pies o las piernas. A esto también se le conoce como angiografía periférica. Para lograrlo se utilizan rayos X y un colorante especial para poder ver el interior de las arterias. Otra técnica conocida es el ultrasonido Doppler, el cual consiste en una técnica especial de ultrasonido que evalúa el movimiento de materiales dentro del cuerpo, permitiendo ver y evaluar la circulación de la sangre a través de arterias y venas del cuerpo.

No obstante, las técnicas mencionadas con anterioridad, pueden llegar a ser incómodas, incluso hasta invasivas. En consecuencia se han propuesto técnicas no invasivas para poder acceder a la vasculatura. Una de las más importantes fue

desarrollada en el campo de la óptica. La técnica Laser Speckle Contrast Imaging, o conocida también como LSCI [2], [3]. Es una técnica desarrollada para medir el flujo sanguíneo de una manera no invasiva.

En base a esta técnica se han propuesto diferentes maneras de medir el flujo sanguíneo tanto en vasculatura expuesta [4] como en vasculatura profunda [5], no obstante, LSCI al ser aplicada para la detección de vasculatura profunda presenta problemas al segmentar la misma, debido a la alto esparcimiento que se genera en capas de piel como la dermis y epidermis.

En consecuencia al problema presentado anteriormente, han surgido propuestas basadas en la combinación de técnicas ópticas e inteligencia artificial. Un ejemplo de ello se puede apreciar en [6] donde se propone el uso de aprendizaje no supervisado en combinación con LSCI para mejorar los resultados obtenidos con el solo uso de LSCI al tratar de detectar vasculatura profunda. Obteniendo una mejora en los resultados, donde la combinación de ambas técnicas logró detectar vasculatura profunda a 1µm de profundidad, en un medio que emula las propiedades ópticas de la piel.

Como se ha mencionado a lo largo de este artículo la piel se comporta como un medio altamente esparcidor. Siendo la reconstrucción de imágenes en medios dispersivos otro de los temas en los que la óptica y la inteligencia artificial han colaborado para proponer soluciones a dicho problema. Esto puede ser apreciado en [7] donde se propone el uso de un modelo de deep learning que permite la reconstrucción de imágenes que han sido proyectadas sobre un medio difuso.

Si bien, esta mención pareciese un tema aislado respecto a la detección de vasculatura en medios altamente dispersivos. No lo es del todo, pues prueba que modelos de deep learning pueden proporcionar una mejora al usarse en conjunto con LSCI para la detección de vasculatura profunda.

III. METODOLOGÍA

Diseño del difusor

Para el diseño del difusor seguimos el procedimiento propuesto en [9] donde, se propone un método para la fabricación y caracterización de tejidos "fantasmas" a base de silicona que permiten emular las propiedades ópticas de tejidos biológicos.

Para la fabricación del difusor se utilizó un conjunto de silicon líquido transparente y un catalizador, ambos usados comúnmente para la fabricación de moldes. Las proporciones utilizadas fueron 9 ml de silicon líquido y 9 ml de catalizador para crear un total de 18 ml. Para agregar dispersión óptica a nuestro "fantasma" se agregó a la mezcla 0.0361 mg de TiO_2 (óxido de titanio). Dando como resultado un "fantasma" con una dispersión óptica de $1mm^{-1}$ y un grosor de 7.5 mm.

Sistema propuesto

El sistema propuesto para la generación de imágenes difusas, se compone por las siguientes 4 partes.

1. Raspberry Pi 3.
2. Pantalla TFT 3.5"
3. Módulo de cámara compatible con raspberry.
4. Difusor caracterizado para emular las propiedades ópticas de la piel.

Todas las partes mencionadas, fueron ensambladas en un soporte diseñado específicamente para este sistema, justo como puede observarse en la figura 1.

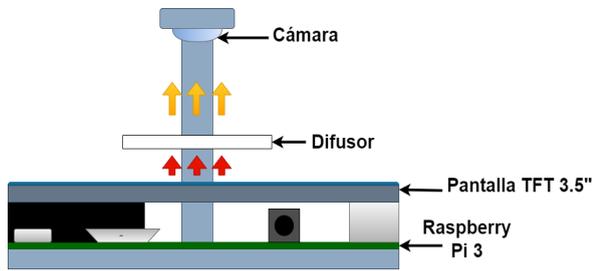


Figura 1. Sistema propuesto para generar imágenes difusas.

Para la generación de nuestro banco de imágenes difusas, desarrollamos un programa que permite proyectar de manera secuencial una cantidad ajustable de imágenes, las cuales son guardadas como imágenes de entrenamiento, el conjunto de entrenamiento se compone de un grupo de imágenes difusas y del mismo grupo de imágenes pero, sin difusión. Para obtener ambos grupos de imágenes el proceso es exactamente el mismo, solo debe retirarse o colocarse el difusor en el arreglo mostrado en la figura 1. Las imágenes proyectadas para este trabajo son de la base de datos Mnist la cual cuenta con 60,000 imágenes de números escritos a mano.

El proceso para la generación del conjunto de imágenes puede apreciarse de manera gráfica en la figura 2.

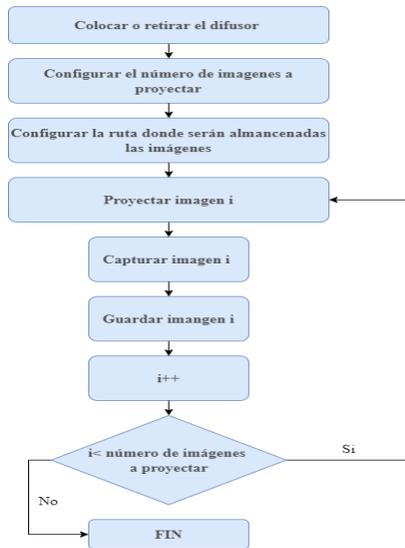


Figura 2. Diagrama de flujo del proceso para crear el conjunto de imágenes.

Pruebas en un modelo de deep learning

El conjunto de entrenamiento creado con nuestro sistema, está compuesto de pares de imágenes tales como las mostradas en la figura 3.

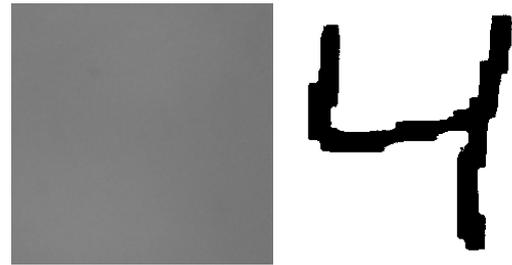


Figura 3. Par de imágenes creadas por el sistema.

El modelo utilizado para probar el conjunto de entrenamiento creado por el sistema propuesto, fue una red neuronal con arquitectura U-net como la que se muestra en la figura 4. Es sabido que la aplicación de la arquitectura U-net está enfocada principalmente en la segmentación de imágenes biomédicas, no obstante, en [7] demuestran que esta arquitectura tiene un buen desempeño en la reconstrucción de imágenes que han sido proyectadas sobre un medio difuso.

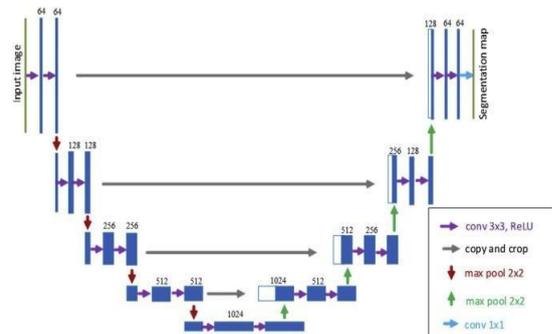


Figura 4. Arquitectura U-net (Imagen tomada del artículo *U-Net: Convolutional Networks for Biomedical Image Segmentation*) [8]

IV. RESULTADOS

Después del entrenamiento mencionado anteriormente, podemos observar en la figura 5 las curvas de pérdida que produce el modelo tanto en el entrenamiento como en la validación. Al comparar la curva naranja correspondiente a la pérdida en la validación del modelo, contra la curva azul correspondiente a la pérdida en el entrenamiento. Es fácil darse cuenta que el modelo no está entrando en sobre ajuste y podríamos suponer que el modelo ha tenido un buen entrenamiento. Sin embargo, los resultados de las predicciones del modelo después del entrenamiento pueden hacernos suponer lo contrario. Estos resultados son mostrados en la figura 6.

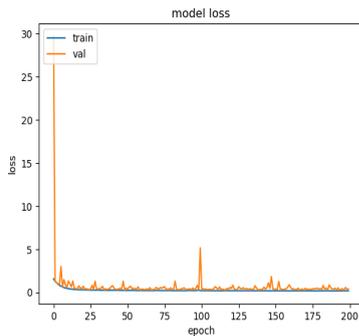


Figura 5. Curvas de pérdida en entrenamiento y validación del modelo con las imágenes creadas por el sistema propuesto.



Figura 6. Imágenes de entrada, predicciones del modelo e imágenes reales respectivamente.

V. CONCLUSIONES

Los resultados obtenidos por el modelo de deep learning utilizado no son los deseados, no obstante, se utilizó el modelo para resaltar que las imágenes que produce el sistema propuesto en este trabajo, permiten entrenar modelos pensados para la reconstrucción de imágenes. En este trabajo no estamos proponiendo un modelo de deep learning para la reconstrucción de imágenes difusas, más bien, estamos proponiendo un sistema *open source* de bajo costo que permita crear conjuntos de entrenamiento enfocados a modelos de deep learning, reconocimiento de patrones y visión computacional. También es importante mencionar que los resultados obtenidos refuerzan nuestra teoría de que al emplear técnicas de inteligencia artificial, específicamente modelos de deep learning, estos pueden contribuir de una manera muy significativa al ser combinados con técnicas ópticas para la detección de estructuras en medios difusos. Dando pie a futuros trabajos relacionados con la detección de vasculatura profunda.

REFERENCIAS

[1] Howard M. Reisner, 'Patología. Un estudio de caso moderno, 2e,' McGraw Hill, vol. 8.

[2] BRIERS J.D., RICHARDS G., HE X.W., Capillary blood flow monitoring using laser speckle contrast analysis (LASCA), *Journal of Biomedical Optics* 4(1), 1999, pp. 164–75

[3] Laser speckle contrast analysis (LASCA): a real-time solution for monitoring capillary blood flow and velocity, *Proceedings of SPIE* 3337, 1998, pp. 98–107.

[4] BRIERS J.D., FERCHER A.F., Retinal blood-flow visualization by means of laser speckle photography, *Investigative Ophthalmology and Visual Science* 22(2), 1982, pp. 255–9

[5] H. Peregrina-Barreto, E. Perez-Corona, J. Rangel-Magdaleno, R. Ramos Garcia, R. Chiu, and J. C. Ramirez-San-Juan, "Use of kurtosis for locating deep blood vessels in raw speckle imaging using a homogeneity representation," *J. Biomed. Opt.* 22(6), 066004 (2017). Vol. 10, No.4 — 1 Apr 2019 — BIOMEDICAL OPTICS EXPRESS 2031

[6] J. A. Arias-Cruz et al., "Visualization of deep blood vessels in speckle imaging using homogeneity measurement of the co-occurrence matrix," *Proc. SPIE* 9660, 966010 (2015).

[7] Yunzhe Li, Yujia Xue, Lei Tian, "Deep speckle correlation: a deep learning approach toward scalable imaging through scattering media", *Optica*, 2018

[8] Ronneberger, O., Fischer, P., and Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation.

[9] F. Ayers, A. Grant, D. Kuo, D. J. Cuccia, and A. J. Durkin, "Fabrication and characterization of silicone-based Vol. 10, No. 4 — 1 Apr 2019 — BIOMEDICAL OPTICS EXPRESS 2030 tissue phantoms with tunable optical properties in the visible and near infrared domain," *Proc. SPIE Design and*, 687007 (2008)