

Una revisión de los métodos de Deep Learning aplicados a la detección automatizada de la retinopatía diabética

José Cuello-Navarro, José Escorcía-Gutiérrez, Carlos Barraza Peña

^{1,2,3}Ingeniería Electrónica y Telecomunicaciones, Universidad Autónoma del Caribe,
Barranquilla, Colombia.

Article History

Received Dec , 16th , 2020

Accepted Dec , 17th , 2020

Published Dec, 18th, 2020



© 2020 The Authors. This article is an Open Access article distributed under the terms and conditions of the Creative Commons Attribution(CC-BY)license

<https://creativecommons.org/licenses/by/4.0>

Abstract

La retinopatía diabética (RD) es una enfermedad ocular caracterizada por cambios anormales a nivel de la retina, que se manifiesta con gran frecuencia en personas que padecen diabetes mellitus. El debido seguimiento y tratamiento puede evitar que la enfermedad afecte gravemente al paciente, sin embargo, debido a la necesidad de contar con profesional especializado y lo costoso del proceso, puede resultar difícil realizar diagnósticos periódicamente, corriendo el riesgo de presentar ceguera. Para contribuir a la solución de dicho problema, se han visto en los últimos años trabajos que emplean tecnología de inteligencia artificial, más precisamente aplicando técnicas de Deep Learning (DL) para el reconocimiento automatizado de los síntomas de la RD presentes en la retina. En este artículo se plantean las bases para la detección de la RD, así como las técnicas DL utilizadas por diversos investigadores para su diagnóstico automatizado y el desempeño de dichos sistemas en este ámbito.

Keywords

Clasificación, Diagnóstico, Procesamiento de imágenes médicas, Redes neuronales convolucionales, Retinopatía diabetic

INTRODUCTION

La retinopatía diabética constituye una de las complicaciones microvasculares más graves asociadas con la diabetes mellitus y representa una causa importante de deterioro visual y ceguera prevenible en la población adulta. Su desarrollo está relacionado con cambios progresivos en los vasos sanguíneos de la retina que, con el tiempo, pueden provocar microaneurismas, hemorragias, exudados y otras alteraciones estructurales. Una de las principales dificultades clínicas es que las primeras fases de la enfermedad pueden avanzar sin síntomas evidentes, lo que hace necesario establecer programas sistemáticos de detección temprana. La identificación oportuna de signos de retinopatía diabética permite iniciar tratamientos y medidas de seguimiento antes de que aparezcan daños visuales irreversibles. Tradicionalmente, la detección de esta enfermedad se ha realizado mediante la evaluación de fotografías del fondo de ojo por especialistas en oftalmología. Aunque este procedimiento puede proporcionar resultados fiables, su aplicación a gran escala presenta dificultades relacionadas con el tiempo, el costo, la disponibilidad de especialistas y el aumento continuo del número de pacientes con diabetes. En países y regiones con acceso limitado a servicios oftalmológicos, estas restricciones pueden dificultar el diagnóstico oportuno y aumentar la probabilidad de complicaciones avanzadas. En este contexto, el desarrollo de herramientas automatizadas para analizar imágenes retinianas ha adquirido una importancia considerable. El Deep Learning, o aprendizaje profundo, constituye una de las

ramas más avanzadas de la inteligencia artificial y ha mostrado resultados prometedores en diferentes áreas del diagnóstico médico por imágenes. A diferencia de los métodos tradicionales de aprendizaje automático, los sistemas de Deep Learning pueden aprender automáticamente características relevantes a partir de grandes volúmenes de datos, sin depender exclusivamente de variables diseñadas manualmente por investigadores. Esta capacidad resulta especialmente útil en el análisis de imágenes del fondo de ojo, debido a la complejidad y diversidad de los patrones asociados con la retinopatía diabética. Las redes neuronales convolucionales se encuentran entre las técnicas más utilizadas para este tipo de aplicaciones. Estas redes pueden identificar automáticamente patrones relacionados con lesiones vasculares, exudados, hemorragias y otras estructuras retinianas. Mediante un proceso de entrenamiento supervisado, el algoritmo aprende a diferenciar imágenes normales de imágenes que presentan distintos grados de retinopatía diabética. Los avances tecnológicos obtenidos hasta 2020 mostraron que varios sistemas de inteligencia artificial podían alcanzar valores elevados de sensibilidad y especificidad. Sin embargo, el desarrollo de algoritmos con alto rendimiento experimental no garantiza automáticamente su utilidad clínica. La calidad de las imágenes, la diversidad de las poblaciones utilizadas para el entrenamiento, la disponibilidad de conjuntos de datos correctamente etiquetados y la capacidad de los modelos para generalizar a nuevos contextos representan factores esenciales. Por esta razón, resulta necesario analizar tanto las fortalezas de los métodos de Deep Learning como sus limitaciones técnicas, metodológicas y clínicas.

Características clínicas de la retinopatía diabética

La retinopatía diabética es consecuencia principalmente del daño progresivo causado por niveles elevados de glucosa sobre la microvasculatura de la retina. En las primeras fases pueden aparecer pequeños microaneurismas, que representan dilataciones localizadas de los vasos sanguíneos. Posteriormente pueden desarrollarse hemorragias retinianas, exudados duros, alteraciones venosas y diferentes signos de daño vascular. La progresión de estas lesiones permite establecer distintos niveles de severidad y determinar el riesgo de pérdida visual. La enfermedad generalmente se clasifica en retinopatía diabética no proliferativa y retinopatía diabética proliferativa. La primera puede dividirse en fases leve, moderada y severa, dependiendo del número y extensión de las lesiones. La fase proliferativa se caracteriza principalmente por la formación de nuevos vasos sanguíneos anormales, que pueden romperse fácilmente y provocar hemorragias vítreas. La clasificación correcta resulta esencial para decidir el seguimiento y el tratamiento clínico adecuado. Desde el punto de vista de la inteligencia artificial, cada una de estas manifestaciones representa patrones visuales que pueden ser identificados mediante algoritmos. El reconocimiento automatizado de estas características facilita la clasificación de imágenes y permite diferenciar pacientes sin enfermedad de aquellos que requieren una evaluación especializada.

Aplicación del Deep Learning en imágenes retinianas

El Deep Learning ha transformado significativamente el análisis automatizado de imágenes médicas debido a su capacidad para identificar patrones complejos. En la retinopatía diabética, los modelos pueden recibir fotografías del fondo de ojo como entrada y generar una predicción asociada con la presencia o ausencia de enfermedad. Dependiendo de la configuración del sistema, también pueden clasificar el nivel de severidad. Durante el entrenamiento, las imágenes son presentadas repetidamente al algoritmo junto con sus correspondientes etiquetas diagnósticas. El sistema ajusta automáticamente sus parámetros internos para reducir los errores entre sus predicciones y la clasificación establecida por especialistas. Este proceso permite que las redes aprendan características que pueden ser difíciles de definir manualmente. Una ventaja importante del Deep Learning consiste en su capacidad para realizar aprendizaje de extremo a extremo. En lugar de establecer múltiples etapas independientes para detectar estructuras específicas, algunos modelos pueden procesar directamente la imagen completa y proporcionar una clasificación final. Esta característica ha contribuido a mejorar la eficiencia de los sistemas automatizados.

Redes neuronales convolucionales

Las redes neuronales convolucionales constituyen una de las principales herramientas empleadas en el reconocimiento automatizado de retinopatía diabética. Su funcionamiento se basa en la aplicación de filtros que analizan diferentes regiones de la imagen. Las primeras capas pueden identificar características sencillas como bordes, líneas y cambios de intensidad, mientras que las capas más profundas pueden reconocer estructuras y patrones complejos. En las fotografías retinianas, las CNN pueden aprender diferencias relacionadas con vasos sanguíneos, microaneurismas, exudados y hemorragias. La información extraída en las diferentes capas se combina progresivamente hasta producir una predicción final. Esta estructura permite analizar imágenes de alta complejidad sin necesidad de definir previamente todas las características relevantes. Arquitecturas como ResNet, VGG y DenseNet han sido adaptadas para aplicaciones relacionadas con el diagnóstico de retinopatía diabética. Cada arquitectura presenta diferencias en cuanto a profundidad, conexiones internas y utilización de características. Sin embargo, el rendimiento final depende de múltiples factores, entre ellos la cantidad de datos disponibles, la calidad de las imágenes y los procedimientos utilizados durante el entrenamiento.

Table 1 Comparación de métodos de Deep Learning utilizados en la detección automatizada de la retinopatía diabética

Método	Aplicación en retinopatía diabética	Ventaja principal	Limitación principal
Redes neuronales convolucionales (CNN)	Clasificación automática de imágenes de fondo de ojo	Extraen características directamente de las imágenes	Requieren grandes conjuntos de datos
ResNet	Identificación de distintos grados de retinopatía diabética	Permite entrenar redes profundas con mayor estabilidad	Alta demanda computacional
DenseNet	Reconocimiento de patrones y lesiones retinianas	Reutiliza características entre diferentes capas	Mayor consumo de memoria
Transfer Learning	Adaptación de modelos preentrenados a imágenes retinianas	Reduce tiempo de entrenamiento y necesidad de datos	Puede presentar limitaciones entre dominios diferentes
Segmentación profunda	Localización de microaneurismas, exudados y hemorragias	Permite identificar regiones específicas de la retina	Requiere imágenes correctamente anotadas
Ensemble Learning	Combinación de varios modelos de Deep Learning	Puede mejorar precisión y estabilidad del diagnóstico	Incrementa la complejidad del sistema

Preprocesamiento y calidad de las imágenes

La calidad de las imágenes representa un factor fundamental en el rendimiento de los algoritmos de Deep Learning. Las fotografías del fondo de ojo pueden presentar diferencias importantes de iluminación, contraste, tamaño y enfoque. También pueden contener artefactos producidos por el dispositivo utilizado, movimientos del paciente o condiciones inadecuadas durante la adquisición. El preprocesamiento busca reducir estas variaciones antes de que las imágenes sean utilizadas por el modelo. Entre las técnicas más frecuentes se encuentran el ajuste del contraste, la normalización de intensidad, el redimensionamiento y la eliminación de regiones irrelevantes. Estas estrategias permiten proporcionar al algoritmo imágenes más consistentes. Otra técnica utilizada es el aumento de datos, mediante el cual se generan nuevas versiones de las imágenes existentes utilizando rotaciones, reflejos, recortes y otras transformaciones. Esta estrategia aumenta artificialmente la diversidad del conjunto de entrenamiento y puede ayudar a disminuir el sobreajuste. Sin embargo, las modificaciones deben conservar las características clínicas importantes para evitar generar datos poco realistas.

Transfer Learning para la detección de retinopatía

El Transfer Learning permite utilizar modelos previamente entrenados en grandes conjuntos de imágenes y posteriormente adaptarlos al análisis de fotografías retinianas. Esta estrategia resulta útil porque el entrenamiento desde cero de una red profunda puede requerir una gran cantidad de datos y recursos computacionales. Las primeras capas de una red previamente entrenada suelen aprender características generales como bordes, formas y texturas. Estas representaciones pueden reutilizarse para tareas médicas mediante un proceso conocido como ajuste fino. Durante este proceso se modifican algunas capas utilizando imágenes específicas de retinopatía diabética. Una de las principales ventajas del Transfer Learning es que permite obtener modelos útiles incluso cuando el conjunto de datos médicos disponible es relativamente pequeño. También puede reducir el tiempo de entrenamiento. Sin embargo, es necesario evaluar cuidadosamente si las características aprendidas originalmente son suficientemente relevantes para el nuevo dominio.

Evaluación del rendimiento de los algoritmos


El rendimiento de los algoritmos de Deep Learning puede evaluarse mediante diferentes métricas estadísticas. Entre las más frecuentes se encuentran sensibilidad, especificidad, exactitud, precisión, F1-score y área bajo la curva ROC. Cada una proporciona información diferente sobre el comportamiento del sistema. La sensibilidad indica la proporción de pacientes con retinopatía diabética que son correctamente identificados por el algoritmo. Una sensibilidad elevada es especialmente importante en programas de detección, porque reduce el número de pacientes enfermos que podrían ser clasificados incorrectamente como normales. La especificidad, por otro lado, representa la capacidad para identificar correctamente a los pacientes sin enfermedad. Una especificidad reducida puede generar un número elevado de falsos positivos y aumentar innecesariamente las derivaciones clínicas. Por esta razón, los modelos deben buscar un equilibrio adecuado entre sensibilidad y especificidad. Las investigaciones publicadas durante 2020 mostraron valores elevados de rendimiento en diferentes sistemas. Sin embargo, las comparaciones entre estudios deben realizarse cuidadosamente, ya que pueden utilizar bases de datos, criterios diagnósticos y metodologías diferentes.

Aplicaciones clínicas y programas de cribado

Una de las aplicaciones más importantes del Deep Learning es su incorporación a programas de cribado de retinopatía diabética. En este contexto, las fotografías del fondo de ojo pueden obtenerse en centros de atención primaria y ser evaluadas automáticamente por un sistema de inteligencia artificial. Los pacientes clasificados como de bajo riesgo pueden continuar con seguimiento rutinario, mientras que aquellos que presentan signos de enfermedad pueden ser derivados a un especialista. Este modelo puede contribuir a reducir la carga de trabajo de los oftalmólogos y mejorar el acceso al diagnóstico. En áreas rurales o regiones con escasez de especialistas, la combinación de inteligencia artificial y telemedicina puede ofrecer beneficios importantes. Las imágenes pueden capturarse localmente y enviarse a sistemas automatizados o especialistas ubicados a distancia. De esta forma, el acceso a programas de cribado puede ampliarse considerablemente. No obstante, antes de implementar estos sistemas es necesario establecer procedimientos claros para manejar imágenes no evaluables, predicciones inciertas y discrepancias entre el algoritmo y el profesional sanitario.

Limitaciones y perspectivas futuras

A pesar de sus ventajas, los métodos de Deep Learning presentan diferentes limitaciones. Una de las principales es la necesidad de grandes cantidades de datos correctamente etiquetados. La creación de estos conjuntos puede ser costosa porque requiere la participación de especialistas. Otra limitación es la falta de interpretabilidad de algunos modelos. Los sistemas pueden proporcionar una predicción sin explicar claramente cómo llegaron a dicha decisión. Esta característica puede generar desconfianza entre profesionales de la salud y dificultar su aceptación clínica. Los problemas de sesgo también requieren atención. Si determinados grupos están insuficientemente representados en los datos de entrenamiento, el rendimiento del algoritmo puede ser menor en estas poblaciones. Por este motivo, resulta fundamental utilizar conjuntos de datos diversos y realizar validaciones multicéntricas. En el futuro, se espera que los sistemas de Deep Learning sean capaces de integrar fotografías retinianas con otros datos clínicos como edad, duración de la diabetes, presión arterial y niveles de glucosa. También puede aumentar el uso de cámaras portátiles y dispositivos móviles, facilitando la detección en comunidades con recursos limitados.



Fuente: Islam et al. (2020), metaanálisis.

Resumen

La retinopatía diabética constituye una de las complicaciones más importantes de la diabetes y puede provocar pérdida visual significativa cuando no se detecta oportunamente. Debido al incremento de la prevalencia de diabetes en diferentes regiones del mundo, la demanda de programas de detección ha aumentado considerablemente. Los métodos tradicionales basados exclusivamente en la evaluación manual de fotografías retinianas presentan limitaciones relacionadas con la disponibilidad de especialistas, los costos y el tiempo requerido para analizar grandes cantidades de

imágenes. El desarrollo del Deep Learning ha creado nuevas posibilidades para automatizar la detección de esta enfermedad. Las redes neuronales convolucionales pueden aprender patrones visuales directamente a partir de fotografías de fondo de ojo y detectar características relacionadas con microaneurismas, hemorragias, exudados y otras lesiones. Diferentes arquitecturas profundas han mostrado resultados prometedores en tareas de clasificación y segmentación. El preprocesamiento de las imágenes constituye una etapa fundamental porque las diferencias en iluminación, contraste y calidad pueden afectar el rendimiento. El aumento de datos y la normalización permiten mejorar la diversidad de los conjuntos de entrenamiento y reducir algunos problemas de sobreajuste. Del mismo modo, el Transfer Learning representa una estrategia eficiente para adaptar modelos previamente entrenados al contexto de la retinopatía diabética. La segmentación automática aporta información adicional porque permite identificar la ubicación de lesiones específicas. Esta característica puede aumentar la interpretabilidad de los resultados y facilitar la evaluación clínica. Sin embargo, la segmentación requiere conjuntos de datos con anotaciones detalladas y precisas. La calidad y diversidad de los datos utilizados durante el entrenamiento representan factores determinantes para la generalización de los modelos. Los algoritmos desarrollados utilizando datos procedentes de una sola población pueden presentar dificultades al aplicarse en otros contextos. En consecuencia, es esencial realizar validaciones externas y utilizar conjuntos multicéntricos. Las métricas utilizadas para evaluar estos sistemas incluyen sensibilidad, especificidad, exactitud y área bajo la curva ROC. Los estudios disponibles en 2020 mostraron niveles elevados de rendimiento en diferentes aplicaciones, aunque existe heterogeneidad entre bases de datos y metodologías. Desde una perspectiva clínica, los sistemas automatizados pueden mejorar los programas de cribado y facilitar la detección en lugares con acceso limitado a especialistas. La integración con telemedicina puede ampliar aún más su utilidad. No obstante, estos sistemas deben ser considerados como herramientas de apoyo y deben integrarse dentro de protocolos clínicos adecuados. Los principales desafíos incluyen la falta de interpretabilidad, la posibilidad de sesgos, la protección de datos, la variabilidad entre dispositivos y la necesidad de validaciones en condiciones reales. Las investigaciones futuras deberán concentrarse en desarrollar modelos más transparentes, robustos y capaces de mantener un rendimiento estable en diferentes poblaciones. En conjunto, la evidencia disponible en 2020 muestra que el Deep Learning posee un elevado potencial para mejorar la detección automatizada de retinopatía diabética. Su aplicación responsable puede contribuir a ampliar la cobertura de cribado, optimizar los recursos sanitarios y facilitar la identificación temprana de pacientes en riesgo de pérdida visual.

Referencias

- Abràmoff, M. D., & Leng, T. (2020). Automated and computer-assisted detection, classification, and diagnosis of diabetic retinopathy. *Telemedicine and e-Health*, 26(4), 544–550.
- Alyoubi, W. L., Shalash, W. M., & Abulkhair, M. F. (2020). Diabetic retinopathy detection through deep learning techniques: A review. *Informatics in Medicine Unlocked*, 20, 100377.
- Burlina, P., Paul, W., Mathew, P., Joshi, N., Pacheco, K. D., & Bressler, N. M. (2020). Low-shot deep learning of diabetic retinopathy with potential applications to address artificial intelligence bias in retinal diagnostics and rare ophthalmic diseases. *JAMA Ophthalmology*, 138(10), 1070–1077.
- Chu, L. C., Chan, C. K. M., Weng, T. W., Chan, S. C. C., & Graham, S. L. (2020). Essentials of a robust deep learning system for diabetic retinopathy screening: A systematic literature review. *Journal of Ophthalmology*, 2020, 8841927.
- Cuello-Navarro, J., Barraza Peña, C., & Escorcía-Gutiérrez, J. (2020). Una revisión de los métodos de Deep Learning aplicados a la detección automatizada de la retinopatía diabética. *Revista Sextante*, 23.
- He, J., Cao, T., Xu, F., Wang, S., Tao, H., Wu, T., Sun, L., & Chen, J. (2020). Artificial intelligence-based screening for diabetic retinopathy at community hospital. *Eye*, 34, 572–576.
- Islam, M. M., Yang, H. C., Poly, T. N., Jian, W. S., & Li, Y. C. J. (2020). Deep learning algorithms for detection of diabetic retinopathy in retinal fundus photographs: A systematic review and meta-analysis. *Computer Methods and Programs in Biomedicine*, 191, 105320.
- Lim, G., Belleño, V., Xie, Y., Lee, X. Q., Yip, M. Y. T., & Ting, D. S. W. (2020). Different fundus imaging modalities and technical factors in AI screening for diabetic retinopathy: A review. *Eye and Vision*, 7, 21.
- Sarki, R., Ahmed, K., Wang, H., & Zhang, Y. (2020). Automatic detection of diabetic eye disease through deep learning using fundus images: A survey. *IEEE Access*, 8, 151133–151149.
- Sengupta, S., Singh, A., Leopold, H. A., Gulati, T., & Lakshminarayanan, V. (2020). Ophthalmic diagnosis using deep learning with fundus images: A critical review. *Artificial Intelligence in Medicine*, 102, 101758.
- Shankar, K., Sait, A. R. W., Gupta, D., Lakshmanaprabu, S. K., Khanna, A., & Pandey, H. M. (2020). Automated detection and classification of fundus diabetic retinopathy images using synergic deep learning model. *Pattern Recognition Letters*, 133, 210–216.

Wang, X. N., Dai, L., Li, S. T., Kong, H. Y., Sheng, B., & Wu, Q. (2020). Automatic grading system for diabetic retinopathy diagnosis using deep learning artificial intelligence software. *Current Eye Research*, 45(12), 1550–1555.