

تأثير أمراض العين على أداء أنظمة التعرف على القرنية باستخدام التعلم العميق

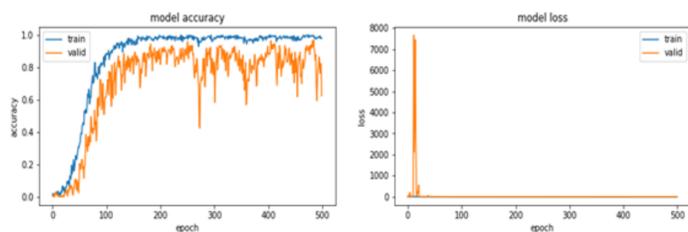
The Effect of Eye Diseases on the Performance of Deep Learning Iris Recognition Systems

إعداد: م.شمسه كمال جركس

بإشراف: د.رأفة خازم
مشرف مشارك: د.محمد الشايطة

النتائج والمناقشة

أوضحت النتائج تفوق نموذج VGG19 على نموذجي Inception-ResNet و ResNet50 و ResNet101، لكن أداء شبكة Inception-ResNet كان الأفضل من بين النماذج الأربعة.



نتائج تدريب شبكة Inception-ResNet على مجموعة بيانات القرنية المختلطة (طبيعية ومرضية)

أما النتائج المتعلقة بتأثير الأمراض في نظام التعرف على القرنية في وجود الأمراض، فقد أوضحت النتائج أن استخدام مجموعة بيانات مرضية قلل الأداء بمقدار لا يتجاوز 3% عن أداء أنظمة التعرف في حال استخدام مجموعات بيانات طبيعية بالكامل، وهذا يعني أن أمراض العين لا تؤثر كثيراً على أداء أنظمة وصف الصور وإنما على نحو جزئي.

Best Model	Disease-based dataset مجموعة بيانات مرضية	Normal Dataset مجموعة بيانات طبيعية	Hybrid dataset مجموعة بيانات مختلطة طبيعية ومرضية
Best Accuracy	97%	100%	97%
Average Training time per epoch الزمن الوسطي لكل تكرار في التدريب	6 s	5 s	6 s

المراجع

- T. Zhao, Y. Liu, G. Huo and X. Zhu, "A deep learning iris recognition method based on capsule network architecture," IEEE Access, vol. 7, no. 2019, pp. 49691-49701, 2019.
- S. Najji, R. Tornai, J. Lafta and H. Hussein, "Iris Recognition Using Localized Zernike Features with Partial Iris Pattern," in International Conference on New Trends in Information and Communications Technology Applications, Baghdad, Iraq, 2020.
- W. Alnahari, "Convolutional Neural Network for Iris Recognition," College of Computers and Information Technologies, 24 Lab 1, University of Bisha, Riyadh, KSA, 2021.

الملخص

يعد التعرف على الأشخاص باستخدام الوصفات والقياسات الحيوية من أكثر المواضيع التي تشكل تحدياً مستمراً لنظم الذكاء الصناعي، لأنها تتطلب تحديثاً دائماً واستخدام أدق الخوارزميات الموجودة للحصول على دقة عالية ونسبة خطأ قليلة جداً.

يقوم هذا البحث بدراسة تأثير أمراض العين في أداء أنظمة التعرف على الأشخاص باستخدام القرنية. ولتحقيق هذا الهدف، تم استخدام أربعة أنظمة تعرف على القرنية باستخدام أربعة أنواع مختلفة من شبكات التعلم العميق، وهي ResNet50، ResNet101 و VGG19، و Inception-ResNet. كما تم استخدام مبدأ التعلم المنقول Transfer Learning في النماذج الأربعة.

القسم النظري

أصبح التعلم العميق Deep Learning جزءاً لا يتجزأ من أنظمة الذكاء الصناعي الحديثة نظراً لقدرته الكبيرة على معالجة البيانات الضخمة وإعطاء نتائج أدق.

جرى تطوير نماذج شبكات تعلم عميق كثيرة انطلاقاً من شبكة CNN لحل مشكلات الشبكات القديمة، بحيث يتم تقليل زمن التدريب الطويل مع رفع الأداء.

تستخدم معظم الشبكات توابع تفعيل لا خطية Relu، كما أنها تعتمد مبدأ الحشو Padding خلال عملية ترشيح الصور، أما بالنسبة إلى تقليل الأبعاد فتتضمن هذه الشبكات طبقات تسمى طبقات الانتخاب Pooling Layers التي تهدف أساساً إلى تقليل حجم الصورة الناتجة من كل مرحلة التفاف.

القسم العملي

تم استخدام ثلاث مجموعات بيانات، وهي مجموعة بيانات طبيعية لا تتضمن أمراضاً، ومجموعة بيانات مرضية تتضمن حالات لأمراض مختلفة للعين، ومجموعة بيانات مختلطة تشمل مجموعتي البيانات الطبيعية والمرضية.

طبقت عملية التجزئة Segmentation وتحويل هاف لكشف الدوائر Circular Hough Transform من أجل تجزئة صور العين والحصول على منطقة القرنية فقط.

وجرى تقسيم البيانات إلى 70% تدريب و 20% تحقق و 10% اختبار.

ونفذت سيناريوهات التدريب الثلاثة على أربعة نماذج تعلم عميق باستخدام مبدأ نقل التعلم Transfer Learning.