

تحديد درجة الأذية المفصالية لمرضى التاعور باستخدام الذكاء الصناعي


Determining The Level of Joint Damage For Hemophilia Patients Using Artificial Intelligence

رسالة مقسمة لتقدير درجة الماجستير في الهندسة الطبية


إعداد: المهندسة سالي وهي بإشراف: الأستاذة الدكتورة هاني عماشة وأستاذة الدكتورة تهاني علي

الطرق العملية


1. مرحلة التلقين معطية مصل اليربة من صورة الأشعة السينية لمرضى التاعور،
 2. مرحلة تصنيف أذية مصل اليربة مرضى التاعور،
 3. في هذه المرحلة يتم تجريبي عدد من طرق علاج مع معالجة أولية على صور الدخل المفصلة YOLOv3 و YOLOv5.



2.2. استخدام نموذج CNN تدريب مسبقاً على قاعدة بيانات ImageNet. هذا النماذج هو Inception-Resnet-V2 [7] وتم التعديل على بنيتها الأصلية لتتناسب إلى تقنية نقل التعلم. حيث تم استبدال الطبقة الأخيرة فيه (طبقة التصنيف) بأربع طبقات جديدة: طبقة تجميع كامع، طبقة متصلة كليا مع ناتج لطيفة ReLU، طبقة تعظيم عمل Dropout، وطبقة مشابهة كليا مكونة من عدد من المعطيات متوافقة لعدد درجات أذية المصل وناتج لتشطيق مسبق ماركس softmax.




3.2. الانتداب على نقل التعلم في المرشحين المكون من مرحلة تصنيف شدّة مرض التهاب المصلل التنكسي. ثم مرحلة تعديل درجة أذية مصلل الكبر. المرحلة الأولى الممثلة بالتشخيص الال لمريضة مرض التهاب المصلل التنكسي وفق معيار كرفين-لورانس قام على نموذج Inception-Resnet-V2 المدرب مسبقاً على الصور الطبيعية الموجودة في قاعدة بيانات ImageNet حيث تم استخدام تقنية نقل التعلم من أجل تكيف نموذج Inception-Resnet-V2 الأصلي على مشكلة التصنيف المعتبرة الخاصة بمرض التهاب المصلل التنكسي. المرحلة الثانية الممثلة بتصنيف الال لمريضة مرض التهاب المصلل التنكسي، حيث تم استخدام تقنية نقل التعلم من أجل تكيف نموذج KOA-Inception-Resnet-V2 المدرب مسبقاً على صور الأشعة السينية لمرض التهاب المصلل التنكسي. حيث تم استخدام تقنية نقل التعلم مرة أخرى من أجل تكيف نموذج KOA-Inception-Resnet-V2 على مشكلة التصنيف المعتبرة بمرض التاعور.



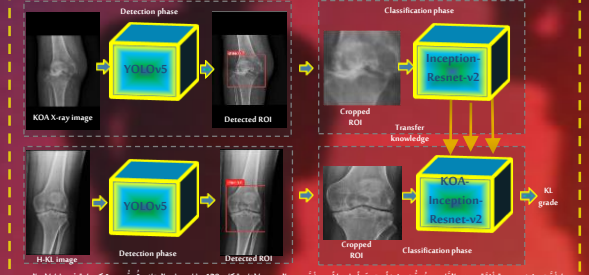
الناتج ومناقشتها

| الطريقة | الزمن الوسيط لمعالجة الصورة (ثانية) | الدقة الكلية % |
|---------|-------------------------------------|----------------|
| HOG+SVM | 30 sec | 93% |
| YOLOv3 | 0.25sec | 97% |
| YOLOv5 | 0.03sec | 98.25% |

2 نتائج التصوير بدرجة أذية مصلل اليربة مرضى التاعور
 1. تحليل الصور باستخدام YOLOv3
 2. تحليل الصور باستخدام YOLOv5
 3. مقارنة النتائج بين الطرق
 4. مقارنة النتائج بين الطرق مع معالجة أولية



أما بالنسبة لقاعدة بيانات صور مصلل اليربة الممثلة وفق معيار كرفين-لورانس H-KL، فقد أعطى النموذج القائم على نقل التعلم في المرشحين أفضل النتائج، حيث بلغت دقة الاختيار 70% تقريبا معطياً 78% بالنسبة للأصناف الخمسة بغير هذه النتيجة على أن النموذج في المرحلة الأولى اكتسب خبرة كافية في التعرف على الصور الطبيعية المتوفرة الموجودة في قاعدة بيانات ImageNet ومن ثم في المرحلة الثانية اكتسب خبرة كافية في التعرف على صور الأشعة السينية لمصلل اليربة المرضي التاعور، الأمر الذي قلل المعلومات غير الالهائية للأسفول من خمسة أصناف وفق كرفين-لورانس. نتائج التصنيف الال لمريضة مرض التهاب المصلل التنكسي وفقا لمعيار كرفين-لورانس.



بدأ أن تصنيف درجة أذية مرض التاعور يُعد تصليفاً متعمداً، فضلاً عن أن عدد الصور الملتقطة كان 120. فإن هذه النتائج تُعد جيدة كبرية في هذا المجال (الجدول 1 مقارنة بين أداء النموذج المُختلفة المستخدمة في مرحلة تعديل درجة أذية مصلل اليربة مرض التاعور).
 76.20% اعتماداً على شبكات التلي العصبونية ونتيجة نقل التعلم وبالتالى مع الدراسات التجريبية المشابهة السابقة. فإن هذا النظام قد أعطى أداء أفضل في نتائج التصنيف بدرجة KI متعدد الأصناف.

| المرحلة | النموذج | الدقة الكلية % | الزمن الوسيط |
|---------|---------------------|----------------|--------------|
| مرحلة 1 | CNN | 52.3% | 18.3 sec |
| | YOLOv3 | 98.25% | 0.03 sec |
| | Inception-Resnet-v2 | 93% | 30 sec |
| | HOG+SVM | 93% | 30 sec |
| مرحلة 2 | CNN | 67% | 18.3 sec |
| | YOLOv3 | 97% | 0.25 sec |
| | Inception-Resnet-v2 | 78% | 30 sec |
| | HOG+SVM | 93% | 30 sec |
| مرحلة 3 | CNN | 67.5% | 18.3 sec |
| | YOLOv3 | 98.25% | 0.03 sec |
| | Inception-Resnet-v2 | 97% | 0.25 sec |
| | HOG+SVM | 93% | 30 sec |

| المرحلة | النموذج | الدقة الكلية % | الزمن الوسيط |
|---------|---------------------|----------------|--------------|
| مرحلة 4 | CNN | 61.66% | 18.3 sec |
| | YOLOv3 | 98.25% | 0.03 sec |
| | Inception-Resnet-v2 | 93% | 30 sec |
| | HOG+SVM | 93% | 30 sec |
| | Random forest | 66.69% | 18.3 sec |
| | YOLOv3 | 98.25% | 0.03 sec |
| | Inception-Resnet-v2 | 93% | 30 sec |
| | HOG+SVM | 93% | 30 sec |
| | YOLOv3 | 98.25% | 0.03 sec |
| | Inception-Resnet-v2 | 93% | 30 sec |




الخص

يُعدّ التاعور Hemophilia اضطراباً نادياً نادياً مرتبطاً بالصبغي X ناتجاً عن نقص في عوامل تخثر الدم. ومن عوامل تخثر الدم. ومن ثم نقص في عوامل تخثر الدم. وقد عُرفت في ذلك الجو مع تكرار حدوث النزيف أكثر أجزاء الجسم تتعرض في المشاكل وبأنّ مصلل اليربة في مقدمتها يُعدّ التصوير الإشعاعي أكثر أنظمة التصوير استخداماً في مرض التاعور، حيث يُستخدم في تحديد العلامات المرئية في المصلل بعدّ نظام تصنيف إرتو-ميلهايرتز أكثر أنظمة التصنيف المستخدمة في تحديد درجة أذية المصلل التاعوري في صور الأشعة السينية. فهو يسهم درجة أذية الوجود العلامات غير المتطيرة في صورة المصلل في ستة درجات كما استخدم نظام تصنيف كرفين-لورانس في تحديد درجة أذية اليربة. وهناك من يستخدم أيضا في تحديد درجة أذية المصلل ودرجات تغير المصلل ومن هذا فإن التمييز بين اليربة والمفصالية في تصوير الأشعة السينية، كما هو مبين في هذه الدراسة، يتطلب من الباحثين تطوير أنظمة تصنيف ذكاء اصطناعي قادرة على التعرف على الصور الطبيعية للأسفول. ونتيجة لهذا الأهمية، فإن تصميم نظام قادر على التصنيف الال لمريضة مرض التهاب المصلل التنكسي أمر هام جداً، ويكون نظام التصنيف الال من جزئين، جزء اكتشاف أشياء من أجل استطاع مصلل المصلل، واخرت شبكة YOLOv5 كمنهج اكتشاف أشياء، وجزء تصنيف ليزيد المناطق المقطعة وقد تم تجريب نظام التصنيف كمنصم شبكة في تصنيف صور المرضى التاعور. استخدام تصنيف ذكاء اصطناعي باستخدام خوارزميات التعرف على الأشياء، وتطبيق معالجة أولية على الصور قبل إرسالها إلى مرحلة التصنيف (إزالة الطبقات الكافية من مرشح الصور)، ونموذج Inception-Resnet-V2 المتعدّد الأصناف في التعرف على الصور الطبيعية وفق معيار كرفين-لورانس. حيث بلغت دقة تصنيف درجة أذية المصلل لمرضى التاعور 72%، حين تم تطبيق نقل التعلم من أجل التعرف على الصور الطبيعية، والمرشحين أفضل النتائج على الصور الطبيعية وفق معيار كرفين-لورانس، حيث بلغت دقة تصنيف درجة أذية المصلل لمرضى التاعور، 70%، حين تم تطبيق نقل التعلم في نظام نقل التعلم في المرشحين نظمو على نما استخدام المعرفة الال لمريضة مرض التهاب المصلل التنكسي. حيث بلغت دقة تصنيف درجة أذية المصلل لمرضى التاعور، 70%، حين تم تطبيق نقل التعلم في المرحلة الثانية. كانت استخدام المعرفة الال لمريضة مرض التهاب المصلل التنكسي في التعرف على صور الأشعة السينية المصنوعة من مرضى التهاب المصلل التنكسي البالغ عددها 4375 صورة بلغت دقة 76.20%. من أجل التمييز الال لمريضة مرض التهاب المصلل التنكسي وكان عدد صور الأشعة السينية المصلل اليربة عند مرضى التاعور المستخدمة 120 صورة. فمرضى التاعور مرض نادر جداً، ومن ثم عند بيانات محدود به محدود جداً يُعدّ هذا البحث الأول من نوعه في استخدام التعلم العميق في تحديد درجة أذية مصلل اليربة مرضي التاعور، ومن ثم تعدّ النتائج التي توصل إليها هذا البحث جيدة كبرية في هذا المجال.


هدف البحث

تصميم نظام قادر ان يعدّد درجة أذية مصلل اليربة عند مرضى التاعور بشكل ان تتماشى تماماً مع نتائج نماذج التعلم العميق Deep learning الممثلة بشبكات التلي العصبونية Convolutional Neural Networks (CNNs) وفقاً لمعيار كرفين-لورانس KI، مما يؤدي إلى تقليل الخطأ البشري ومن ثم وصف العلاج المناسب لمرحلة اليربة المصلي.



الدراسات المرجعية

النماذج المرجعية الطبية
 نظام تعلم عميق معسور (المرحلة الثانية) [1]
 نظام تعلم عميق (المرحلة الأولى) [2] الذي يعكس أسوأ الفترات التشريحية في المصلل
 أما بالنسبة للدراسات التقنيّة فلا يوجد دراسات مرجعية عن التصنيف الال لمريضة مرض التهاب المصلل التنكسي. وكان النظام العام للتشخيص الال القائم على التعلم العميق مكون من مرحلتين: مرحلة تعديل منطقة أذية الانجمام (ROI) (منطقة المصلل) من صورة الأشعة السينية، ثم مرحلة تصنيف ليزيد المناطق المستهدفة.



المراجع

- [1] Peterson, H., Abbeg, A. and Nilsson, L.M. (1986). A radiologic classification of hemophilic arthropathy. *Clinical Orthopaedics and Related Research*. New York, United States: Springer Science+Business Media.
- [2] Arnold, W.D. and Huggener, M.W. (1974). Hemophilic arthropathy. Current concepts of pathogenesis and management. *Bone Joint Surg Am*, pp. 287-305. Boston, MA: United States. Journal of Bone and Joint Surgery.
- [3] Redmon, J., Divvala, S., Girshick, R. and Farhadi, A. (2016). *You Only Look Once: Unified, Real-Time Object Detection*. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, Nevada, USA.
- [4] YOLOv5 Is Here: State-of-the-Art Object Detection at 440 FPS. Available online: <https://blog.roboflow.com/yolov5-is-here/> (accessed on 5 may 2022).
- [5] Chen, Y.-W. and Jira, I. G. (2020). *Deep Learning in Healthcare: Paradigms and Applications*. P. 225. Cham, Switzerland: Springer Nature.
- [6] Yamashita, K., Nishio, M., Do, R. K. G., and Togashi, K. (2018). *Convolutional neural networks: an overview and application in radiology*. Insights into Imaging, vol. 9, pp.611–629. Germany: Springer Science +Business Media, Deutschland GmbH.
- [7] Szepesvári, C., Balafoutis, S., Vrabucovic, V., and Alami, A. (2016). Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. *arXiv preprint arXiv:1602.07264v2*.
- [8] Antony, J., McKeown, K., Mouna, K. and O'Connell, E. (2017). Automatic detection of knee joints and quantification of knee osteoarthritis severity using convolutional neural networks. *arXiv preprint arXiv:1701.09460v1*.
- [9] Talpin, T., Jahn, A., Thevenoz, J., Rahin, E., Lehenkar, P., and Szankáls, S. (2018). Automatic Knee Osteoarthritis Grading from Plain Radiographs: A Deep Learning Based Approach. *Sci Rep*, vol. 8, no. 1, pp.1-7. United Kingdom: Nature Publishing Group.
- [10] Chen, Y.-W., Guo, L., Shi, X., Allen, K. and Yang, L. (2019). Fully automatic knee osteoarthritis severity grading using deep neural networks with a novel ordinal loss. *Computational Intelligence and Graphics*, vol. 7A, pp.384-392. United Kingdom: Elsevier Ltd.
- [11] Talpin, A., Szankáls, S. (2020). Automatic grading of individual knee osteoarthritis features in plain radiographs using deep convolutional neural networks. *BMC Med*, vol. 18, no. 11, pp. 932-942. Switzerland: MDPI.
- [12] Thomas, K. A., Kadirowski, L., Talpin, E., Pennig, S. L., Vehtakarman, G.R., Qiu, E. H. G., Gold, G. E. and Dady, S. L. (2020). Automated classification of radiologic knee osteoarthritis severity using deep neural networks. *Journal of Bone and Joint Surgery*, vol. 2, issue 2. *Biomedical Artificial Intelligence*. United States: Radiological Society of North America.
- [13] Swickci, A. L., N. O'Donnell, J. Sind, N. Yang, J. Mauer, R. C. et al. (2021). *Deep Learning-Based Approach for Assessment of knee osteoarthritis severity in radiographs matches assessments of radiologists*. *Biometrics in Biomedicine and Medicine*, vol. 13, p. 9. Elsevier.
- [14] Wang, Y., Wang, X., Guo, T., Du, L. and Liu, W. (2021). *An Automated Knee Osteoarthritis Diagnosis Method Based on Deep Learning*. Data from the Osteoarthritis Initiative. *Journal of Healthcare Engineering*, volume 2021, Article ID 5586292, p.10. Egypt: Hindawi Limited.
- [15] Rodgers, J. and Lawrence, J. (1977). Radiological assessment of knee arthropathy. *Ann Rheum Dis*, vol. 16, issue 4, pp.494-500. London: English, H.K. Lewis.