



HAL
open science

Réseau de neurones récurrent à attention pour la détection de lésions intestinales

Rémi Vallée, A de Maissin, Harold Mouchère, A Boureille, Antoine Coutrot,
Nicolas Normand

► **To cite this version:**

Rémi Vallée, A de Maissin, Harold Mouchère, A Boureille, Antoine Coutrot, et al.. Réseau de neurones récurrent à attention pour la détection de lésions intestinales. ORASIS, May 2019, Saint-Dié-des-Vosges, France. hal-02283753

HAL Id: hal-02283753

<https://hal.science/hal-02283753>

Submitted on 11 Sep 2019

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Réseau de neurones récurrent à attention pour la détection de lésions intestinales

R. Vallée¹ A. Coutrot¹ H. Mouchère¹ N. Normand¹
A. De Maissin² A. Boureille²

¹ Laboratoire des Sciences du Numérique de Nantes

² Centre Hospitalier et Universitaire de Nantes

remi.vallee@univ-nantes.fr

Résumé

La maladie de Crohn (MC) est une maladie inflammatoire chronique intestinale, atteignant les sujets jeunes, provoquant des lésions de l'intestin grêle : des érosions, des ulcérations, de l'œdème et des sténoses. La vidéo-capsule endoscopique (VCE) est le meilleur examen permettant leur détection. La VCE génère environ 50000 images dont l'analyse par les gastro-entérologues est consommatrice de temps. L'objectif de notre travail est donc de développer un outil permettant la reconnaissance automatique des lésions de MC dans l'intestin grêle. L'algorithme est basé sur un réseau de neurones convolutifs à attention. Celui-ci a été entraîné sur une base de données publique, GIANA, contenant des images de VCE normales et avec des lésions inflammatoires et vasculaires. Une autre base a été utilisée séparément, CROHN-IPI, constituée d'images normales et de lésions de MC annotées par des gastro-entérologues du CHU de Nantes. Les résultats préliminaires montrent que l'algorithme entraîné sur les 1800 images de GIANA, est capable de distinguer avec une précision de 99,77% les images pathologiques des images non pathologiques. Concernant CROHN-IPI, la précision obtenue sur les 2500 images provenant de 39 patients est de 80,36%. Cet écart peut s'expliquer par la façon dont ont été sélectionnées les images de la base (images de lésions plus évidentes dans GIANA) ou encore par la sous-représentation de certaines pathologies dans CROHN-IPI. À l'avenir, une application d'annotation de VCE à plus grande échelle sera développée pour enrichir CROHN-IPI.

Mots Clef

Apprentissage profond, réseau récurrent à attention, maladie de Crohn, classification d'images médicales.

Abstract

Crohn's disease (CD) is a chronic inflammatory bowel disease, affecting young subjects, causing mucosal damage to the small intestine : erosions, ulcerations, edema and stenosis. The wireless capsule endoscopy (WCE) is the best examination for their detection. The WCE generates ap-

proximately 50,000 images that are time-consuming for gastroenterologists to analyse. The objective of our work is therefore to develop a tool for the automatic recognition of mucosal lesions of CD in the small intestine. The algorithm is based on a network of convolutional neurons with attention. This was trained on a public database, GIANA, containing images of normal WCEs and with inflammatory and vascular lesions. Another database was used separately, CROHN-IPI, consisting of normal images and MC lesions annotated by gastroenterologists from Nantes University Hospital. Preliminary results show that the algorithm trained on the 1800 GIANA images, is able to detect with an accuracy of 99,77% the pathological images. Concerning CROHN-IPI, the accuracy obtained on the 2500 images from 39 patients is 80.36%. This difference can be explained by the way the images in the database were selected (images of more obvious lesions in GIANA) or by the under-representation of certain pathologies in CROHN-IPI. In the future, a larger scale WCE annotation application will be developed to enrich CROHN-IPI.

Keywords

Deep learning, recurrent attention model, Crohn's disease, medical images classification.

1 Introduction

Depuis le milieu des années 1990, le développement de la VCE a permis une avancée dans le diagnostic des maladies gastro-intestinales. Cette technologie peu invasive présente des performances de diagnostic importantes du fait de sa capacité à rendre possible l'exploration complète des 3 à 4 mètres d'intestin grêle. Elle est maintenant bien acceptée par l'ensemble de la communauté scientifique [1]. La maladie de Crohn et l'angiodyplasie sont deux maladies dont le diagnostic repose en grande partie sur la détection de lésions intestinales qui peuvent grâce à la VCE être plus facilement détectées.

Le diagnostic de la maladie de Crohn repose sur deux scores : *The Capsule Endoscopy Crohn's Disease Activity Index* (CECDAI) [2] et le score de Lewis [3]. Ces indica-

teurs sont corrélés au nombre de lésions, à leurs types et à leurs localisations dans l'intestin. Ces scores dépendent du nombre et de l'identification précise des lésions, il est nécessaire que les experts gastro-entérologues visionnent l'ensemble des 50 000 images générées par la VCE pour chaque patient, ce qui peut s'avérer très consommateur en temps.

Différents systèmes ont été développés dans le but de limiter le temps d'analyse des données par les gastro-entérologues en identifiant les images potentiellement pathologiques. De nombreux efforts ont été réalisés dans le but de détecter les lésions intestinales à partir d'images obtenues par VCE [4–9]. Ces travaux peuvent être classés en deux catégories principales : les algorithmes basés sur des techniques *ad hoc* présentées dans la section 2.1 et les algorithmes basés sur des réseaux de neurones convolutifs (CNN), présentés dans la section 2.2. Ces réseaux permettent l'extraction automatique de caractéristiques les rendant plus résilients, mais également plus complexes à entraîner du fait du nombre important de données nécessaires pour ajuster leurs très nombreux paramètres.

Grâce au partenariat entre le Centre Hospitalier et Universitaire de Nantes et le Laboratoire des Sciences du Numérique, une importante quantité de données a pu et pourra être annotée. De plus, à l'heure actuelle, une plateforme d'annotation collaborative est en cours de réalisation, ce qui permettra dans le futur d'obtenir une plus grande quantité de données afin d'améliorer l'entraînement d'un réseau de neurones profond. Le choix a donc été fait de réaliser un réseau de neurones récurrent à attention à la manière de Mnih *et al.* [10]. Ce réseau, plutôt que de prendre en entrée la totalité de l'image, choisit grâce à un apprentissage non-supervisé plusieurs patches successivement extraits dans l'image d'origine qui permettront de prendre une décision de classification à l'issue de ces multiples regards sur la même image. Ainsi le fonctionnement du réseau se rapproche du comportement oculaire de l'être humain.

L'objectif de ce réseau est double. Il permet la classification des images endoscopiques pour l'aide au diagnostic et tout en permettant la comparaison avec le comportement des experts face à des images issues de VCE. Dans cet article, il sera présenté dans un premier temps l'état de l'art, puis l'architecture du réseau de neurones et enfin les résultats obtenus ainsi que leur analyse.

2 État de l'art

2.1 Méthodes *Ad hoc*

La première catégorie d'algorithmes non-basés sur l'apprentissage profond, se concentre l'extraction de caractéristiques des images issues de VCE. Un classifieur est entraîné pour faire le lien entre les caractéristiques et l'appartenance de l'image à une classe. Yu *et al.* [4] utilisent par exemple le descripteur *Local Binary Pattern* (LBP) ainsi que le descripteur *Scale Invariant Feature Transform* (SIFT) avant de procéder à la classification à l'aide d'un

Support Vector Machine (SVM) afin de détecter les images contenant des ulcères. D'autres algorithmes, comme celui développé par Li *et al.* [5] se basent sur l'extraction des couleurs des images en partant du constat que la couleur des ulcères est majoritairement blanche/jaune, en utilisant ensuite un réseaux de perceptrons multicouches pour réaliser la classification. On trouve également les techniques basées sur l'extraction de texture comme réalisé par Chen *et al.* [6]. Le problème de cette première catégorie est qu'elle est peu robuste aux variations d'éclairage, d'angle de vue et souvent spécifique à un type de lésion, la rendant donc plus difficilement applicable en situation réelle.

2.2 Méthodes basées sur l'apprentissage profond

Depuis 4 ans, de nouveaux algorithmes ont été développés dans le but de réaliser la segmentation et la détection de lésions à partir d'images issues de VCE. Ces algorithmes reposent sur des réseaux de neurones profonds. Ces réseaux se démarquent de par leurs différentes architectures et les données utilisées pour les entraîner. Aoki *et al.* [7] proposent un réseau basé sur une architecture nommée Single Shot multibox Detector [11]. Ce réseau apprend à générer des boîtes de délimitation autour des zones considérées comme pathologiques. Fan *et al.* proposent un algorithme de détection utilisant le réseau AlexNet [12] entraîné sur leur propre base de données contenant 8000 images de VCE. On trouve également dans la littérature un réseau de neurones profond nommé TeraNetV2 [13], réseau permettant la segmentation d'images. Cet algorithme a été appliqué à la segmentation d'images issues de VCE [9] et a obtenu la première place lors de la compétition GIANA [14]. Ces différents algorithmes étant testés sur des bases de données différentes il est difficile de comparer leurs performances.

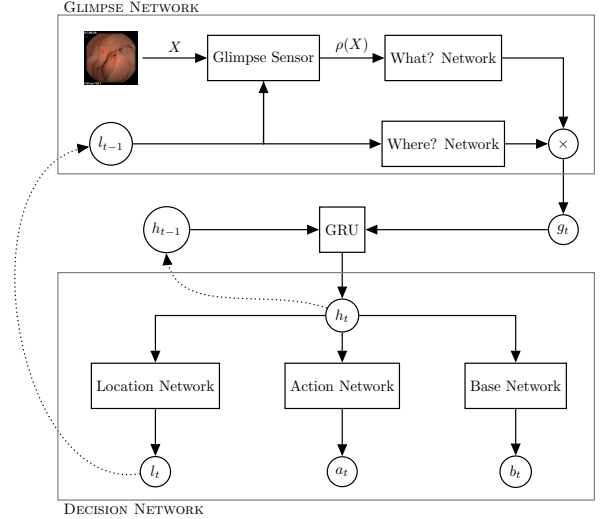
3 Architecture du réseau

3.1 Réseau de neurones à attention

Dans cet article on considère l'attention comme un processus de décision séquentiel d'un agent interagissant avec un environnement visuel. On fournit au réseau d'entrée une image endoscopique X . Le Glimpse Sensor (voir figure 1) va ensuite extraire un patch $\rho(X)$ de l'image d'origine en fonction de $l_t = (x, y, z)$ avec x et y les coordonnées normalisées entre $[-1; 1]$ et $(0, 0)$ le centre de l'image. z est un coefficient de zoom compris entre $]0; 1]$. Avec $s_x \times s_y$ la résolution de l'image d'origine, on obtient un patch de résolution $(s_x \times z) \times (s_y \times z)$ aux coordonnées $(s_x \times x, s_y \times y)$. Ce patch est ensuite redimensionné pour conserver une taille fixe en entrée du réseau. Le sous-réseau *What? Network*, basé sur VGG16 [15] pré-entraîné sur ImageNet [16], permet d'extraire les caractéristiques du patch $\rho(X)$. Seules les couches convolutives du VGG et la première couche *fully-connected* ont été conservées.

En parallèle, les informations relatives à l'extraction du patch l_t traversent le *Where? Network* composé de 2 couches *fully-connected*, permettant ainsi l'extraction des caractéristiques relatives à la position d'extraction du patch $\rho(X)$. Les deux vecteurs de caractéristiques produits par ce réseau sont alors de taille identique et seront sommés avant de subir une non-linéarité *rectified linear unit* (ReLU). Le nouveau vecteur caractéristique g_t en sortie de la non-linéarité contient alors les informations "Où?" et "Quoi?" extraites par le *Glimpse Network* au temps t . Une Gated Recurrent Unit [17] (GRU) permet ensuite de fusionner les caractéristiques extraites au temps t par le réseau avec celles extraites au temps précédent contenu dans l'état interne précédent h_{t-1} de la GRU. Cet état interne de la GRU sera réutilisé au temps suivant.

À partir du nouvel état interne produit par la GRU, l'*action network* va produire un vecteur associant un score à chacune des classes. Le *Baseline Network* va lui permettre de calculer la récompense associée à une prédiction afin de pouvoir entraîner le *Location Network* par renforcement. L'apprentissage par renforcement est non-supervisé et associe à chaque action du réseau une récompense qui devra être maximisée par ce dernier. Ainsi le réseau va augmenter la probabilité des localisations maximisant la fonction récompense. Si le réseau classe correctement l'image, la récompense vaut alors le nombre de regards placés sur l'image auquel est soustraite la baseline calculée par le réseau.



3.2 Fonction de coût

La fonction de coût du réseau est une combinaison linéaire de trois sous-fonctions de coût (voir Équation 1). Elle est similaire à celle présentée par Mnih *et al.* 2014 [10].

$$\mathcal{L} = \mathcal{L}_a + \mathcal{L}_b + \mathcal{L}_r \quad (1)$$

Premièrement \mathcal{L}_a (voir Équation 2) la fonction d'entropie croisée permettant de calculer l'erreur de classification du réseau lors du dernier regard sur l'image avec \hat{Y}_i la prédiction du réseau et Y_i la vérité terrain.

$$\mathcal{L}_a = -\frac{1}{n} \sum_{i=1}^n Y_i \log(\hat{Y}_i) \quad (2)$$

Ensuite la fonction \mathcal{L}_b (voir Équation 3), calculant l'erreur quadratique moyenne entre la récompense R_t^i et la baseline b_t établie par le réseau. La récompense est égale au nombre de regards posés sur l'image si elle a été correctement classifiée, 0 sinon. Cette *baseline* dépendant du contexte présent et passé, permet d'ajuster la récompense de sorte à pousser le réseau à s'améliorer par rapport à ses résultats précédents.

$$\mathcal{L}_b = \frac{1}{n} \sum_{i=1}^n \sum_{t=1}^T (b_t - R_t^i)^2 \quad (3)$$

FIGURE 1 – **Architecture du réseau à attention** : À chaque temps t , on fournit au *Glimpse sensor* une image endoscopique X et la localisation l_{t-1} du patch à extraire de l'image d'origine. Deux réseaux de neurones indépendants, le *What? Network* et le *Where? Network*, vont ensuite permettre l'extraction des informations relatives au contenu et à la localisation du patch. Une Gated Recurrent Unit (GRU) va ensuite permettre de fusionner les caractéristiques extraites précédemment par le réseau contenu dans le vecteur h_{t-1} avec g_t afin de produire l'état actuel du système h_t . À partir de cet état, trois sous-réseaux vont produire indépendamment l_t la position du prochain patch à extraire, a_t un vecteur contenant un score associé à chacune des classes et b_t , la *baseline* à partir de laquelle est calculée la récompense de l'apprentissage par renforcement.

La fonction \mathcal{L}_r (voir Équation 4) permet de mettre en place l'apprentissage non-supervisé par renforcement. Le principe est le suivant : une stratégie $\pi(\tau^j; \theta)$, dépendante des paramètres du réseau θ associe une probabilité au trajet τ^j . Un trajet est une succession d'actions u_t , dans notre cas le changement de la localisation de l'extraction d'un patch. Chaque action entraîne un nouvel état s_t , dans notre cas un nouveau patch en entrée du système. Ce nouvel état influence alors le système qui produira une nouvelle action qui conduira à un nouvel état. Ainsi l'objectif de l'algorithme de renforcement est de maximiser la probabilité des trajets qui maximise la récompense ($R_t - b_t$) et *a contrario* de diminuer celle des trajets conduisant à une récompense faible. En réalisant la somme des récompenses associées aux différents trajets possibles M par leurs probabilités respectives, on obtient la fonction de coût de l'algorithme d'apprentissage par renforcement.

$$\mathcal{L}_r = -\frac{1}{n} \frac{1}{M} \sum_{i=1}^n \sum_{j=1}^M \sum_{t=1}^T \log \pi(u_t^j | s_{i:t}^j; \theta) (R_t^j - b_t) \quad (4)$$

3.3 Initialisation du premier regard

À chaque nouvelle image, la matrice d'état h_0 de la GRU est remise à zéro afin que chacune des prédictions soit indépendante. Il est proposé ici d'étudier deux possibilités d'initialisation du premier regard sur l'image. La première, dite libre, laisse le réseau apprendre à positionner lui-même son premier regard. Ce premier regard est alors dépendant de la dernière image vue. La deuxième possibilité, dite centrée, s'inspire du comportement humain. Quelle que soit la répartition de l'information dans l'image, lors de l'apparition d'une nouvelle image, l'homme a tendance à regarder son centre. Ce phénomène est appelé biais de fixation central. Ainsi à chaque nouvelle image, le réseau est forcé de procéder à un regard central englobant toute l'image $(x, y, z) = (0, 0, 1)$.

La comparaison entre le comportement des premières zones du cortex visuel humain et celui des réseaux de neurones est possible d'après Cichy *et al.* [18]. Ainsi, l'effet du biais de fixation central sur les performances du réseau est un premier pas sur l'étude des stratégies d'exploration humaine à travers l'étude du comportement d'un réseau de neurones artificiels.

4 Résultats et discussion

Les différents algorithmes de segmentation et de détection d'images médicales cités précédemment ont chacun été testés sur des bases de données différentes, ne contenant pas toutes les mêmes types de lésions et avec des images ayant des lésions plus ou moins évidentes. Cette hétérogénéité des bases de données ne permet pas de pouvoir bien comparer les algorithmes entre eux et leur efficacité en condition réelle. C'est pour pallier ce problème que nous avons choisi, en plus de tester et entraîner notre algorithme sur notre propre base de données CROHN-IPI,

d'également l'entraîner et l'évaluer sur GIANA, une base de données utilisée lors d'un challenge à MICCAI 2017 [19], mais dont l'étiquetage de la base de test reste secret.

4.1 Résultats sur Giana

Le *dataset* contient 1800 images obtenues par VCE réparties en 3 classes : 600 images avec des lésions vasculaires, 600 avec des inflammatoires et 600 ne contenant aucune pathologie. Les images de la base d'entraînement subissent des transformations aléatoires lors de l'entraînement afin d'augmenter la diversité des exemples permettant ainsi au réseau de généraliser plus facilement. 50% des images de la base sont utilisées pour entraîner le réseau et 50% pour l'évaluation. Pour obtenir des résultats statistiquement significatifs, on entraîne et évalue le réseau sur 10 *sous-datasets*. La matrice de confusion présentée figure 2 montre les résultats cumulés sur les 10 différents *sous-datasets*. On obtient alors une précision de 86,33% sur la tâche de classification entre les trois classes. On remarque que la majorité des erreurs commises par le réseau est principalement concentrée dans la classification des lésions inflammatoires en lésions vasculaires et inversement.




FIGURE 2 – Matrice de confusion pour 10 entraînements/tests sur la base de données GIANA

Notre problème concernant la détection des lésions, les classes lésions vasculaires et lésions inflammatoires ont été regroupées en une classe "pathologique" sans réentraînement. Les résultats obtenus pour les différentes configurations du réseau sont présentés dans le tableau 1. Deux méta-paramètres ont varié lors de ces expériences, l'initialisation du premier regard sur l'image et le nombre de regards placés sur chaque image. Les meilleurs résultats sont obtenus pour 4 regards sur l'image. Une précision maximale de 87,51% est obtenue pour la tâche de classification à trois classes (lésion inflammatoire, lésion vasculaire et non pathologique) en laissant la localisation du premier regard libre. La précision maximal sur la tâche de classifi-

Nombre de regards	3 classes		2 classes			
	Précision	Précision	Spécificité	Sensibilité	F1	F2
3	85,42%	98,67%	98,53%	98,97%	99,23%	99,50%
3 centrés	84,37%	99,60%	99,77%	99,23%	99,43%	99,63%
4	87,51%	99,30%	99,44%	99,03%	99,28%	99,53%
4 centrés	86,34%	99,77%	99,84%	99,63%	99,73%	99,82%
5	86,46%	99,01%	99,10%	98,83%	99,13%	99,43%
5 centrés	86,46%	98,75%	98,58%	99,10%	99,33%	99,56%

TABLE 1 – Tableau récapitulatif de l’effet du biais de fixation central et du nombre de regards par image sur la base de données GIANA

cation à deux classes (pathologique, non pathologique) est de 99,77% soit une erreur toutes les 434 images. Sur la deuxième tâche, le meilleur résultat est obtenu en forçant le premier regard à englober l’ensemble de l’image. Des exemples de regards sur quatre images de GIANA sont présents figure 3.

4.2 Résultats sur CROHN-IPI

La base de données de CROHN-IPI comprend 2590 images réparties en 8 classes différentes, 7 correspondant à des types de lésions pathologiques différentes (ulcération aphthoïde, ulcération de 3 à 10 mm, ulcération de plus de 10 mm, œdème, sténose, érythème, pseudo-polype) et une classe contenant des images d’intestins non-pathologiques. Ces données ont été annotées par deux gastro-entérologues et proviennent de 39 patients différents.

Les images n’étant pas équitablement réparties entre les classes, les classes pathologiques ont été regroupées. L’entraînement du réseau sur cette base se fait sur 970 images équitablement réparties en 2 classes : intestins sains et intestins pathologiques. Le test se fait sur les 1 620 images restantes comprenant 70% d’images pathologiques et 30% de non-pathologiques. Les résultats obtenus sont regroupés dans les tableaux 2 et 3. Une précision maximale de 80,36% est obtenue après *cross-validation* sur 10 *sous-datasets* différents, pour une architecture procédant à 4 regards de résolution 80 par 80 sur l’image issue de VCE. Trois principaux méta-paramètres du réseau ont subi des variations : la résolution du patch d’entrée du réseau, le nombre de regards posés sur l’image et l’initialisation du premier regard.

4.3 Évaluation du biais de fixation central artificiel

Comme présenté précédemment, une expérience a été menée dans le but d’évaluer l’efficacité du biais de fixation central artificiel sur une tâche de classification d’images endoscopiques. 24 entraînements et tests différents (voir tableaux 1, 2 et 3) ont été réalisés dans le but de vérifier l’hypothèse que le biais de fixation central permet d’améliorer les scores du réseau. Ces 24 entraînements et tests sont *cross-validés* sur 10 *sous-datasets* différents d’en moyenne 1300 images. Un test de permutation a été ef-

fectué sur les résultats des 240 sous-entraînements/tests. On calcule l’écart ΔM entre la moyenne du groupe de contrôle, contenant les précisions associées aux 120 entraînements/tests sans biais, avec celle du groupe de test contenant les 120 entraînements/tests avec le biais central. Suite à cela, 10000 permutations aléatoires sont réalisées entre les différents groupes. Pour chaque permutation, une nouvelle moyenne est calculée. On peut alors calculer la p_{value} de ce test comme étant la proportion des moyennes obtenues par permutation supérieure à ΔM par rapport au nombre de permutations réalisées. On obtient à l’issue de ce test $p = 0,185$ ce qui ne permet pas de valider l’hypothèse que le biais central améliore la précision du réseau. Le tableau 4 contient les résultats du test de permutation obtenus pour les différentes métriques en fonction des résultats obtenus sur les différents *datasets*. À partir de ce tableau, il est possible de valider l’hypothèse de départ sur le *dataset* GIANA, la p_{value} obtenue sur la précision étant nettement inférieure à 5%. Cependant la généralisation de l’hypothèse de départ n’est pas possible au vu des résultats. On peut remarquer que le biais de fixation central améliore la spécificité du réseau, c’est à dire sa capacité à reconnaître les images non-pathologique des images pathologiques.

4.4 Discussion

Les résultats obtenus sont largement inférieurs sur la base de données CROHN-IPI par rapport à ceux sur la base de données GIANA (une erreur toutes les 5 images sur Crohn-IPI contre une erreur toutes les 400 images sur GIANA). Cet écart peut s’expliquer de plusieurs manières. Premièrement, les lésions inflammatoires de l’angiodyplasie sont nettement plus reconnaissables de par leur couleur rouge vif que les lésions de la maladie de Crohn. Deuxièmement, le *dataset* GIANA comprend 600 images de chacune des lésions et 600 images non-pathologiques, ce qui permet au réseau de pouvoir s’entraîner sur 300 exemples avant d’être testé. Pour CROHN-IPI, certaines classes de lésions comme les sténoses ou les érythèmes sont sous-représentées dans le *dataset* (moins de 70 exemples). Ensuite, cela peut aussi s’expliquer par la façon dont ont été choisies les images de GIANA par rapport à celles de CROHN-IPI. Les images de GIANA semblent nettement plus "propres", contenant moins de bruit lié à la




FIGURE 3 – Exemples de regards sur 4 images de GIANA. La colonne A présente un cas de lésion inflammatoire correctement classifiée, la colonne B un cas de lésion vasculaire correctement classifiée, la colonne C un cas d’image non pathologique correctement classifiée, la colonne D un cas de lésion inflammatoire classée en lésion vasculaire.

Nombre de regards	2 classes				
	Précision	Spécificité	Sensibilité	F1	F2
3	76,66%	71,68	88,14%	90,65%	93,30%
3 centrés	78,55%	74,40%	88,10%	90,72%	93,51%
4	80,03%	77,23%	86,47%	89,59%	92,93%
4 centrés	77,86%	73,30%	88,36%	90,88%	93,53%
5	78,24%	74,24%	87,47%	90,23%	93,17%
5 centrés	79,77%	76,81	86,61%	89,68%	92,97%

TABLE 2 – Tableau récapitulatif de l’effet du biais de fixation central et du nombre de regards par image sur la base de données CROHN-IPI.

capture de l’image (flou, faible luminosité) et de bruit lié à l’activité intestinale (moins de bulles sur les images).

5 Conclusion

Cet article présente la mise en place d’une architecture de réseau de neurones récurrent à attention. Elle a été entraînée et testée sur deux *datasets* différents : GIANA et CROHN-IPI obtenant une précision de 99,77% et 80,36% respectivement. Les différentes expériences menées ont pu

Taille des patchs	2 classes				
	Précision	Spécificité	Sensibilité	F1	F2
112x112	80,03%	77,23%	86,47%	89,59%	92,93%
112x112 centrés	77,86%	73,30%	88,36%	90,88%	93,53%
96x96	79,45%	76,22%	86,86%	89,84%	93,04%
96x96 centrés	77,48%	72,94	87,93	90,54	93,30
80x80	80,36%	77,34%	87,32%	90,24%	93,36%
80x80 centrés	78,34%	74,47%	87,24%	90,07%	93,08%
64x64	78,22%	73,36%	89,42%	91,71%	94,11%
64x64 centrés	79,83%	76,47%	87,57%	90,40%	93,41%
48x48	78,17%	73,84%	88,16%	90,75%	93,49%
48x48 centrés	78,56%	74,42%	87,14%	90,00%	93,06%
32x32	75,82%	70,08%	89,05%	91,30%	93,65%
32x32 centrés	77,16%	72,41%	88,10%	90,64%	93,34%

TABLE 3 – Tableau récapitulatif de l’effet du biais de fixation central et de la résolution des patchs extraits par le *Glimpse Sensor* sur les performances du réseau sur la base de données CROHN-IPI.

Métrique	p_{GIANA}	p_{CI}	p
Taille de l’échantillon	60	180	240
Précision	0,014	0.226	0.185
Spécificité	0.009	0.217	0.245
Sensibilité	0.898	0.377	0.594

TABLE 4 – Tableau des différentes p_{value} obtenues par test de permutations sur les différentes métriques selon les différents *datasets*.

montrer le bon fonctionnement du réseau de par sa capacité à classifier avec une grande précision les images pathologiques des non-pathologiques sur le *datasets* GIANA. Les résultats sur CROHN-IPI, le *dataset* construit en partenariat avec le CHU de Nantes, restent cependant mitigés du fait du nombre d’images "compliquées" qu’il contient. L’ajout de nouveaux exemples à cette base de données, grâce à un outil d’annotation en cours de développement, devrait permettre au réseau d’assimiler de nouveaux cas et ainsi d’améliorer les résultats.

Ce travail a également permis d’étudier une première hypothèse de comparaison entre le comportement cognitif humain et celui d’un réseau artificiel au travers de l’étude de la technique d’exploration du réseau. Bien que les résultats ne permettent pas d’attester des similarités entre eux, il sera toujours possible d’explorer ces pistes grâce à de futures expériences.

Références

- [1] Marisol Luján-Sanchis, Laura Sanchis-Artero, Laura Larrey-Ruiz, Laura Peño-Muñoz, Paola Núñez-Martínez, Génesis Castillo-López, Lara González-González, Carlos Boix Clemente, Cecilia Albert Antequera, Ana Durá-Ayet, and Javier Sempere-García-Argüelles. Current role of capsule endoscopy in Crohn’s disease. *World journal of gastrointestinal endoscopy*, 8(17) :572–83, sep 2016.
- [2] Eyal Gal, Alex Geller, Gerald Fraser, Zohar Levi, and Yaron Niv. Assessment and Validation of the New Capsule Endoscopy Crohn’s Disease Activity Index (CECDAI). *Digestive Diseases and Sciences*, 53(7) :1933–1937, jul 2008.
- [3] I. M. Gralnek, R. Defranchis, E. Seidman, J. A. Leighton, P. Legnani, and B. S. Lewis. Development of a capsule endoscopy scoring index for small bowel mucosal inflammatory change. *Alimentary Pharmacology & Therapeutics*, 27(2) :146–154, oct 2007.
- [4] L. Yu, P. C. Yuen, and J. Lai. Ulcer detection in wireless capsule endoscopy images. In *Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012)*, pages 45–48, Nov 2012.
- [5] Baopu Li and Max Q.-H. Meng. Computer-based detection of bleeding and ulcer in wireless capsule endoscopy images by chromaticity moments. *Computers in Biology and Medicine*, 39(2) :141–147, 2009.
- [6] Yingju Chen and Jeongkyu Lee. Ulcer detection in wireless capsule endoscopy video. In *Proceedings of the 20th ACM International Conference on Multimedia*, MM ’12, pages 1181–1184, New York, NY, USA, 2012. ACM.
- [7] Tomonori Aoki, Atsuo Yamada, Kazuharu Aoyama, Hiroaki Saito, Akiyoshi Tsuboi, Ayako Nakada, Ryota Niikura, Mitsuhiro Fujishiro, Shiro Oka, Soichiro Ishihara, Tomoki Matsuda, Shinji Tanaka, Kazuhiko Koike, and Tomohiro Tada. Automatic detection of erosions and ulcerations in wireless capsule endoscopy images based on a deep convolutional neural network. *Gastrointestinal Endoscopy*, 2018.
- [8] Shanhui Fan, Lanmeng Xu, Yihong Fan, Kaihua Wei, and Lihua Li. Computer-aided detection of small

intestinal ulcer and erosion in wireless capsule endoscopy images. *Physics in Medicine & Biology*, 63(16) :165001, aug 2018.

- [9] Alexey A. Shvets, Vladimir I. Iglovikov, Alexander Rakhlin, and Alexandr A. Kalinin. Angiodysplasia detection and localization using deep convolutional neural networks. In *ICMLA*, pages 612–617. IEEE, 2018.
- [10] Volodymyr Mnih, Nicolas Heess, Alex Graves, and Koray Kavukcuoglu. Recurrent Models of Visual Attention. jun 2014.
- [11] Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott E. Reed, Cheng-Yang Fu, and Alexander C. Berg. SSD : single shot multibox detector. *CoRR*, abs/1512.02325, 2015.
- [12] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. ImageNet Classification with Deep Convolutional Neural Networks. In F Pereira, C J C Burges, L Bottou, and K Q Weinberger, editors, *Advances in Neural Information Processing Systems 25*, pages 1097–1105. Curran Associates, Inc., 2012.
- [13] Vladimir I Iglovikov, Selim S Seferbekov, Alexander V Buslaev, and Alexey A Shvets. TerausNetV2 : Fully Convolutional Network for Instance Segmentation. Technical report.
- [14] Xavier Dray, Cynthia Li, Jean-Christophe Saurin, Franck Cholet, Gabriel Rahmi, JP Le Mouel, C. Leandri, Stéphane Leclaire, Xavier Amiot, Jean-Michel Delvaux, Clotilde Duburque, R Gérard, Romain Leenhardt, F Mesli, G Vanbervliet, I. Nion-Larmurier, Sylvie Sacher-Huvelin, Camille Simon Simon Chane, Olivier Romain, and Aymeric Histace. CAD-CAP : une base de données française à vocation internationale, pour le développement et la validation d’outils de diagnostic assisté par ordinateur en vidéocapsule endoscopique du grêle. In Thieme, editor, *Actes des JFHOD 2018*, volume 50 of *Endoscopy*, page 316, Paris, France, March 2018.
- [15] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *CoRR*, abs/1409.1556, 2014.
- [16] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei. ImageNet : A Large-Scale Hierarchical Image Database. In *CVPR09*, 2009.
- [17] Kyunghyun Cho, Bart van Merriënboer, Dzmitry Bahdanau, and Yoshua Bengio. On the properties of neural machine translation : Encoder–decoder approaches. In *Proceedings of SSST-8, Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation*, pages 103–111. Association for Computational Linguistics, 2014.
- [18] Radoslaw M Cichy, Aditya Khosla, Dimitrios Pantazis, Antonio Torralba, and Aude Oliva. Comparison of Deep Neural Networks to Spatio-temporal Cortical Dynamics of Human Visual Object Recognition reveals Hierarchical Correspondence. *Scientific Reports*, 2016.
- [19] Jorge Bernal, Nima Tajikbakhsh, Francisco Javier Sanchez, Bogdan J. Matuszewski, Hao Chen, Lequan Yu, Quentin Angermann, Olivier Romain, Bjorn Rustad, Ilanko Balasingham, Konstantin Pogorelov, Sungbin Choi, Quentin Debarde, Lena Maier-Hein, Stefanie Speidel, Danail Stoyanov, Patrick Brandao, Henry Córdova, Cristina Sánchez-Montes, Suryakanth R. Gurudu, Gloria Fernández-Esparrach, Xavier Dray, Jianming Liang, and Aymeric Histace. Comparative validation of polyp detection methods in video colonoscopy : Results from the MICCAI 2015 endoscopic vision challenge. *IEEE Trans. Med. Imaging*, 36(6) :1231–1249, 2017.