

IA et imagerie médicale

Applications à l'imagerie cardiovasculaire

Alain Lalande

alain.lalande@u-bourgogne.fr



Alain Lalande

Quelques mots me concernant



Maître de Conférence en Biophysique et Imagerie médicale
Praticien Hospitalier en Biophysique

Directeur adjoint du laboratoire ICMUB (Université de Bourgogne) et rattaché au
Centre Hospitalier Universitaire de Dijon depuis 2000

Principaux domaines de recherche :

- IRM (notamment du système cardiovasculaire)
- Post-traitement d'images médicales (via des techniques d'apprentissage profond)
- Réalité augmentée en chirurgie


Co-organisateur du challenge ACDC en 2017

Organisateur du challenge EMIDEC en 2020

91 publications scientifiques dans des journaux internationaux (selon le site pubmed)
Principales publications dans Nature Genetics, IEEE Transactions on Medical
Imaging, Investigative Radiology et Medical Image Analysis.

Qu'est ce que l'apprentissage automatique (Machine Learning) ?

L'apprentissage automatique est un domaine de l'informatique qui permet aux ordinateurs d'apprendre sans être explicitement programmés.



Des méthodes capables d'apprendre à partir de données et de faire des prédictions sur de nouvelles données.

Modélisation d'un modèle

- ➔ Avec des équations issues de la mécanique, physique, chimie, etc. Reproduction des phénomènes connus avec une vérité théorique.
- ➔ Modélisation avec des équations complexes explicites ($y=f(x)$) en mimant le phénomène (calibré sur une population la plus large possible).
- ➔ Modélisation avec des équations implicites ($F(x,y) = a$, méthode dite « boîte noire »), avec le besoin de beaucoup de données.

Types d'apprentissage

Supervisé: Apprentissage à partir de données étiquetées

- Classification des e-mails avec des e-mails déjà étiquetés
- Segmentation du cœur à partir d'une IRM



Non supervisé: Découverte de motifs dans des données non étiquetées

- Regrouper des documents similaires en fonction du texte
- Trouver des régions homogènes dans une image

Apprentissage par renforcement : Apprendre à agir en fonction d'un retour ou d'une récompense

- Apprendre à jouer au jeu de Go. Récompense : gagner ou perdre
- Segmentation d'image. Récompense : correction (potentiellement manuelle)


Qu'est ce que l'apprentissage profond (Deep Learning) ?



➔ Réseau de neurones

Si vous fournissez au système une grande quantité d'informations, il commence à les comprendre et à réagir de manière adaptée.

Qu'est ce que l'apprentissage profond en segmentation d'image médicale?



Modèle HDLSS



High Dimension, Low Sample Size

Chaque image médicale peut contenir beaucoup d'information (des milliers voire des millions de points) mais le nombre de cas reste très limité (nombre de patients dans une étude par exemple).

L'apprentissage profond n'est pas adapté à un modèle HDLSS (sauf si le modèle est contraint)

- ➔ Risque de sur-apprentissage
- ➔ Instabilité des modèles statistiques

Neurone artificiel



Activation de l'entrée du neurone
(fonction d'entrée)

➔ w : Poids

➔ b : Biais


Fonction de sortie

➔ g : Fonction d'activation

$$a(x) = \sum_i w_i x_i + b$$

$$z = g(a(x))$$

Réseau de neurones




Réseau de neurones en traitement d'image

Réseau de neurones convolutionnels


Convolutional neural network (CNN)

Une entrée (comme une image) peut avoir une dimension très élevée. Utiliser un réseau de neurones entièrement connecté nécessiterait un grand nombre de paramètres.


Les CNN (réseaux de neurones convolutifs) sont un type particulier de réseau de neurones dont les couches cachées ne sont connectées qu'à une partie de l'image. Ainsi, le nombre de paramètres nécessaires pour les CNN est bien plus réduit.



Opération de convolution




Exemple de convolution dans un CNN



Le réseau U-Net

(Réseau dédié à la segmentation des images biomédicales)




Le modèle U-Net est composé de deux chemins, l'un pour l'analyse (encodeur) et l'autre pour la synthèse (décodeur).

L'encodeur est constitué de couches de convolution et de sous-échantillonnage (pooling) qui contractent spatialement l'image tout en capturant l'information contextuelle.

Le réseau U-Net


(Réseau dédié à la segmentation des images biomédicales)



Le modèle U-Net est composé de deux chemins, l'un pour l'analyse (encodeur) et l'autre pour la synthèse (décodeur). Le décodeur permet une reconstruction précise de la localisation en étendant la sortie pour obtenir une carte de probabilité de segmentation avec la résolution initiale.

Le réseau U-Net

(Réseau dédié à la segmentation des images biomédicales)



Existence de connexions directes (raccourcis) entre les couches de même résolution entre l'encodeur et le décodeur.

Les couches d'expansion bénéficient des caractéristiques en haute résolution transmises par ces connexions.



**Antennes spécifiques pour
l'imagerie cardio-vasculaire**




Orientation des plans de coupe - IRM

Plan de coupe « 2 cavités »

Grand axe vertical du ventricule gauche

Grand axe du cœur, passant au niveau de l'apex (pointe) et de la jonction auriculo-ventriculaire.



Orientation des plans de coupe - IRM


Plan de coupe « 4 cavités »

Ventricule droit

Grand axe horizontal du ventricule gauche

Grand axe du cœur, passant au niveau de l'apex (pointe) et de la jonction auriculo-ventriculaire.

Perpendiculaire au grand axe « 2 cavités ».




Orientation des plans de coupe - IRM

Plan de coupe « petit axe »

Petit axe du ventricule gauche

Perpendiculaire aux 2 grands axes.


Résolution temporelle moyenne en routine clinique: ~ 20 à 30 msec / image



Etude de la fonction cardiaque



Paramètres fonctionnels

- ➔ Volume maximal (diastolique) de la cavité cardiaque (ventricule gauche et ventricule droit)
- ➔ Fraction d'éjection (fraction de sang éjecté du ventricule durant un cycle cardiaque)
- ➔ Masse myocardique (du ventricule gauche)
- ➔ Epaisseur et épaisseissement du myocarde (du ventricule gauche)



Masse et volume de la cavité du ventricule gauche

Le volume de la cavité du ventricule gauche est calculé à partir de la somme de l'aire de la cavité cardiaque A_i mesurée sur toutes les coupes en orientation petit-axe couvrant le ventricule, multipliée par la distance d entre deux coupes.



La masse du ventricule gauche a été calculée à partir du volume myocardique multiplié par la densité du tissu myocardique ($1,05 \text{ g/cm}^3$). Le volume myocardique est obtenu à partir de la différence entre le volume calculé avec les contours épicaudiques et le volume de la cavité.

Challenge : Segmentation automatique des structures cardiaques


- ➔ Pour extraire ces paramètres objectifs, nécessité de connaître les contours cardiaques en diastole et en systole.
- ➔ Tracé manuel de ces contours long et fastidieux
- ➔ Segmentation automatique des contours cardiaques.

Challenges :

- Robustesse
- Précision
- Généralisation (fonctionne dans n'importe quel centre clinique et à partir de données de n'importe quelle machine)
- Rapide (sans être temps réel)
- L'utilisation de réseau de neurones nécessite d'avoir accès à beaucoup de données annotées

Challenge : Accès à la vérité terrain

Quel niveau d'expertise est nécessaire pour créer les vérités de terrain (par exemple, la segmentation manuelle des contours du cœur sur des images ciné-IRM) ?



Challenge : Accès à la vérité terrain

U-Net					
Test Set	ACDC Trainset	Loss	Avg. DSC	Avg. HD	Avg. Mass Err.
ACDC	Expert	CE+Dice	0.88 ± 0.03	11.02 ± 6.25	16.88 ± 9.66
	Non-Expert 1	CE + Dice	0.82 ± 0.03	11.45 ± 4.88	$36.40^* \pm 13.37$
		MAE + Dice	0.86 ± 0.03	11.69 ± 5.18	$15.93^{\dagger} \pm 8.95$
	Non-Expert 2	CE + Dice	0.87 ± 0.03	10.13 ± 5.02	$11.68^* \pm 7.74$
		MAE + Dice	0.89 ± 0.03	10.43 ± 5.00	$6.58^{*,\dagger} \pm 5.93$
	Expert	CE+Dice	0.80 ± 0.06	17.57 ± 7.65	17.36 ± 12.87
M&Ms	Non-Expert 1	CE + Dice	0.76 ± 0.08	14.91 ± 8.60	$22.14^* \pm 19.71$
		MAE + Dice	0.78 ± 0.09	14.32 ± 7.95	$18.78^{\dagger} \pm 17.80$
	Non-Expert 2	CE + Dice	0.80 ± 0.07	14.29 ± 7.53	16.36 ± 13.69
		MAE + Dice	0.80 ± 0.07	13.76 ± 6.79	$19.44^{*,\dagger} \pm 16.79$


➔ Des données annotées par des non-experts bien formés produisent des résultats comparables à ceux obtenus à partir de données annotées par un expert.

Challenge : Rareté des données

Augmentation des données

Les méthodes d'apprentissage profond nécessitent de grosses bases de données expertisées

- Manque de données expertisées dans le domaine médical
- Récupérer des données dans le domaine médical est long et difficile
- L'annotation manuelle est contraignante et nécessite des spécialistes
- Augmentation synthétique des données
- Utilisation de réseaux antagonistes génératifs



GAN (generative adversarial network)

Réseau antagoniste génératif




Image réelle vs image synthétique ?

Image réelles : B, C, E, G

<https://gans.devpods.com>

➔ Amélioration des résultats de segmentation automatique pouvant être relativement minime

Segmentation automatique du ventricule gauche et du ventricule droit à partir d'images IRM. Un problème résolu?

Automatic segmentation of the LV and the RV from cine-MRI.
Is the problem solved ?

MICCAI conference – Grand challenge




Conférence MICCAI (Medical Image Computing and Computer Assisted Intervention)

Pendant la conférence MICCAI, il y a des « Grands défis en analyse d'images biomédicales »

- Comparaison de nouvelles méthodes et des méthodes existantes sur les mêmes ensembles de données pour un sujet particulier
- Mise en évidence des avantages et des inconvénients de chaque méthode (classement des différentes méthodes)
- Ensemble de données d'entraînement disponible longtemps avant le défi et ensemble de données de test disponible pendant une courte période (ou uniquement accessible pendant la conférence)



Automated Cardiac Diagnosis Challenge



Alain Lalande¹, Olivier Bernard², Clement Zotti³, Frédéric Cervenansky², Olivier Humbert⁴, Pierre-Marc Jodoin³

¹Le2i et CHU Dijon, Dijon, France


²CREATIS, Lyon, France

³Université de Sherbrooke, Sherbrooke, Canada

⁴Centre Antoine-Lacassagne, Nice, France



Automated Cardiac Diagnosis Challenge



Alain Lalande¹, Olivier Bernard², Clement Zotti³, Frédéric Cervenansky², Olivier Humbert⁴, Pierre-Marc Jodoin³

¹Le2i et CHU Dijon, Dijon, France

²CREATIS, Lyon, France

³Université de Sherbrooke, Sherbrooke, Canada

⁴Centre Antoine-Lacassagne, Nice, France

Automated cardiac diagnosis challenge (ACDC)

Challenge MICCAI

Cadre

- Post-traitement des images ciné-IRM cardiaques en orientation petit-axe
- Base de données avec différentes pathologies bien définies



Objectifs (Deux évaluations indépendantes)

- 1) Segmentation de l'endocarde et de l'épicarde du ventricule gauche ainsi que de l'endocarde du ventricule droit sur chaque image en diastole et en systole
- 2) Classification automatique des examens en cinq classes (examen normal, insuffisance cardiaque systolique avec infarctus du myocarde, cardiomyopathie dilatée, cardiomyopathie hypertrophique, ventricule droit anormal)

Evaluation des différentes méthodes

➔ Métriques géométriques comme l'indice de Dice ou la distance de Hausdorff

$$dc(y_{true}, y_{pred}) = \frac{2 \sum y_{true} \times y_{pred}}{\sum y_{true} + y_{pred}}$$



➔ Métriques cliniques. Calcul des paramètres cliniques et comparaison entre les valeurs obtenues manuellement et automatiquement


Resultats du challenge

TABLE IV
CLINICAL METRICS FOR THE 10 EVALUATED METHODS ON THE TESTING DATASET. **Red** IS THE BEST METHOD, AND **Blue** ARE THE METHODS WITHIN A P-VALUE LARGER THAN 0.05 ACCORDING TO BIAS AND STD MEASUREMENTS.


Methods *	<i>LV_{EDV}</i>			<i>LV_{EF}</i>			<i>RV_{EDV}</i>			<i>RV_{EF}</i>			<i>MY_{Mass}</i>		
	corr	bias	std	corr	bias	std	corr	bias	std	corr	bias	std	corr	bias	std
	val.	ml.	ml.	val.	%	%	val.	ml.	ml.	val.	%	%	val.	mg.	mg.
Isensee <i>et al.</i> [42]	0.997	2.7	5.7	0.991	0.2	3.1	0.988	4.4	10.8	0.901	-2.7	6.2	0.989	-4.8	7.6
Khened <i>et al.</i> [44]	0.997	0.6	5.5	0.989	-0.5	3.4	0.982	-2.9	12.6	0.858	-2.2	6.9	0.990	-2.9	7.5
Zotti <i>et al.</i> [50]	0.997	9.6	6.4	0.987	-1.2	3.6	0.991	-3.7	9.2	0.872	-2.2	6.8	0.984	-12.4	9.0
Un gagnant mais 5 méthodes très proches (toutes basées sur l'apprentissage profond)															
Iziritas-Grinias [47]	0.992	2.0	11.7	0.975	-1.6	5.0	0.930	18.6	25.4	0.758	-0.5	9.1	0.942	-28.9	28.0
Yang <i>et al.</i> [49]	0.894	12.2	32.0	0.926	1.5	8.7	0.986	-10.8	11.6	0.793	-3.2	8.3	N/A	N/A	N/A

* *LV_{EDV}*: End diastolic left ventricular volume; *LV_{EF}*: Left ventricular ejection fraction; *RV_{EDV}*: End diastolic right ventricular volume; *RV_{EF}*: Right ventricular ejection fraction; *MY_{Mass}*: Myocardial mass in diastole.

Quelques résultats....



GT



GT

Resultats de l'équipe gagnante du challenge





Fig. 3: Time-series segmentation for RVC (red), LVM (green), LVC (blue) and their corresponding volume dynamics. The example shows the central slice in z direction of a healthy patient (NOR).

Quelques commentaires...


- Les méthodes de segmentations sont complètement automatiques.
- Résultats entre les 5 premiers vraiment très proches avec des méthodes performantes.
- Est-ce que le problème est résolu ?
 - ➔ Globalement.....oui !
 - ➔ Le temps de traitement d'un examen est raisonnable pour une utilisation en routine clinique.

Quelques commentaires...

- Est-ce que le problème est résolu ?
 - ➔ En fait, non, car (pour la meilleure méthode), 41 patients sur 50 ont au moins une image avec segmentation impossible anatomiquement.
 - ➔ Les méthodes doivent être validées sur des données provenant d'autres hôpitaux et d'autres constructeurs.





Les résultats du challenge ACDC démontrent que les réseaux de neurones convolutionnels sont très performants pour la segmentation du ventricule gauche et droit sur des coupes ciné-IRM en petit-axe mais....




Challenge : Comment gérer les mauvaises segmentations ?

→ Erreurs entraînant des segmentation aberrantes




→ Challenge : Apprentissage profond pour la segmentation d'IRM cardiaques avec garanties anatomiques

Réseau GridNet avec utilisation d'information a priori



GridNet avec utilisation d'information a priori




Zotti C, Luo Z, Lalande A, Jodoin PM. Convolutional Neural Network With Shape Prior Applied to Cardiac MRI Segmentation. IEEE J Biomed Health Inform. 2019. 23(3):1119-1128.

Explicabilité - XAI (eXplainable AI)

- ➔ Comprendre comment un algorithme d'intelligence artificielle fonctionne et prend ses décisions.
- ➔ Utilisation dans la prédiction (classification) plutôt que dans la segmentation.

Processus secondaire pour expliquer le modèle (Grad-CAM)






Intrinsèque au modèle

- ➔ Grad-CAM peut produire une carte de chaleur à partir de la dernière couche de convolution du réseau de neurones.
- ➔ Le but des cartes de saillance est d'observer l'impact de chaque pixel sur la prédiction du modèle.

Borys K, Schmitt YA, Nauta M, Seifert C, Krämer N, Friedrich CM, Nensa F. Explainable AI in medical imaging: An overview for clinical practitioners – Saliency-based XAI approaches. Eur J Radiol. 2023;162:110787

Salih A, Boscolo Galazzo I, Gkontra P, Lee AM, Lekadir K, Raïsi-Estabragh A, Petersen SE. Explainable Artificial Intelligence and Cardiac Imaging: Toward More Interpretable Models. Circ Cardiovasc Imaging 2023 16(4):e014519.

Exemple de Grad-CAM



Segmentation de la cavité
du ventricule gauche


Grad-CAM

Viabilité myocardique - Détermination par IRM

- Viabilité myocardique : Capacité du myocarde à retrouver sa fonctionnalité après revascularisation, suite à un infarctus du myocarde.
- L'IRM de rehaussement tardif (DE-MRI) est une méthode de référence pour détecter et évaluer l'étendue d'un infarctus du myocarde.
- L'IRM de rehaussement tardif, combinée à l'évaluation de l'épaississement du muscle à partir de ciné-IRM, permet d'évaluer la viabilité myocardique.
- Actuellement, il n'existe pas de méthode automatique efficace pour évaluer les examens d'IRM de rehaussement tardif (le traitement manuel étant très chronophage).

Imagerie de perfusion cardiaque

Imagerie de rehaussement tardif



Imagerie de perfusion cardiaque

Imagerie de rehaussement tardif

Acquisition en apnée environ 10 minutes après l'injection du produit de contraste.

Petit à petit, le produit de contraste est éliminé principalement par les reins, et sa concentration diminue dans le myocarde. Les zones normales apparaissent en hyposignal.

Dans les régions altérées, le produit de contraste s'accumule en raison des effets conjugués de la diffusion, de l'absence d'élimination du produit de contraste et de l'espace interstitiel anormalement augmenté (œdème ou fibrose).



→ Ces zones apparaissent en hypersignal.

Obstruction microvasculaire permanente

Le phénomène de no-reflow



Les zones présentant des lésions microvasculaires importantes se caractérisent par une zone hypo-rehaussée persistante, même sur les images tardives, correspondant à une obstruction microvasculaire permanente.





Phénomène de no-reflow

Zone centrale de l'infarctus du myocarde, correspondant à une obstruction et à des lésions microvasculaires importantes (notamment au niveau des capillaires).

Infarctus du myocarde avec no-reflow



Fonction cardiaque



Imagerie de rehaussement tardif

Challenge :

Gérer des données de différentes sources

- ➔ Simuler le comportement du médecin qui s'appuie sur différents types de données pour faire son diagnostic (clinique, imagerie, biologique, etc.).
- ➔ Renforcement de la robustesse du modèle.
- ➔ Différents caractéristiques et format : Normalisation très complexe des données. Fusion d'information très difficile.
- ➔ Fusion de l'information en entrée du réseau, au milieu ou en sortie du réseau.

EMIDEC challenge


automatic Evaluation of Myocardial Infarction from Delayed-Enhancement Cardiac MRI

Alain Lalande, Zhihao Chen, Dominique Gin hac,
Thomas Decourselle, Abdul Qayyum, Thibaut Pommier,
Michel Salomon, Raphaël Couturier, Fabrice Meriaudeau

Challenge EMIDEC



- Segmentation des différentes regions d'intérêt
- Classification des examens à partir de données d'imagerie et clinique




Site internet du challenge: <http://emidec.com/>

Lien via la conférence: <http://www.miccai.org/events/challenges/>

Base de données – Imagerie de rehaussement tardif



- 150 examens avec des cas normaux (1/3) et pathologiques (2/3, avec ou sans zones de no-reflow). Série d'images en orientation petit-axe couvrant le ventricule gauche.
- Évaluation sur un ensemble de test avec 50 examens.



Caractéristiques cliniques

Nom	Commentaire	Type	Exemple
Cas	Nom de l'examen	Chaine de caractères	Case P001
Sexe	Sexe	Caractère (F ou M)	F
Age	Age en année	Nombre	71
Tabac	Tabac(Oui, non ou ancien fumeur)	Nombre entre 1 et 3	1
Surpoids	Surpoids si BMI > 25	Caractère (Y/N)	Y
Hypertension artérielle		Caractère (Y/N)	Y
Diabète		Caractère (Y/N)	Y
Antécédents familiaux de maladie coronarienne	Antécédents d'événements cardiovasculaires	Caractère (Y/N)	Y
ECG	Présence d'un IDM	Caractère (Y/N)	Y
Troponine	Marqueur biologique	Nombre (données en ng par mL de sang)	11
Killip max	Stratification du risque	Nombre entre 1 et 4	2
Fraction d'éjection du ventricule gauche	Valeur calculée à partir de l'échographie	Pourcentage	45
NTProBNP	Marqueur biologique	Nombre (données en pg par mL de sang)	229


Quelques exemples de segmentation...




Zhang Y, Cascaded Convolutional Neural Network for Automatic Myocardial Infarction Segmentation from Delayed-Enhancement Cardiac MRI. In STACOM. 2020

Girum KB, Skandarani Y, Hussain R, et al. Automatic myocardial infarction evaluation from delayed-enhancement cardiac MRI using deep convolutional networks. In STACOM. 2020.


Quelques exemples de segmentation...




Challenger A




Challenger B




Challenger C




GT



Challenger D




Challenger E




Challenger F


Quelques cas difficiles avec des segmentation aberrantes




Challenger A




Challenger B



GT




Challenger C



Challenger D

Challenge concernant la classification



Challenge concernant la classification

Classification based on clinical features and MRI		
#	Authors	Classification Accuracy
1	Ma 🏆	92%
2	Lourenco et al. 🏆	82%
3	Ivantsits et al. 🏆	78%
4	Sharma et al.	62%
N/A	Shi et al.*	94%
N/A	Girum et al.*	84%


* Co-author comes from the challenge organization team. Do not participate the ranking.

Challenge : Répartition hétérogène des classes


- ➔ Les données sont souvent déséquilibrées, ce qui entraîne des difficultés pour entraîner des modèles performants et justes.
Exemple: Il y a plus de points représentant le fond d'une image que la région à segmenter
- ➔ Sous représentation d'une classe par rapport à une autre.
- ➔ Le modèle peut favoriser les classes majoritaires
Exemple: Ne considérer que le fond de l'image
- ➔ Donner un poids plus élevé aux erreurs commises sur les classes minoritaires pour encourager le modèle à prêter plus d'attention à ces classes.
- ➔ Utilisation de métriques adaptées

Scanner X (tomodensitométrie)

Algorithmes de reconstruction



MPR





VRT

Scanner X des coronaires

Reconstruction 3D

- Synchronisation cardiaque
- Utilisation de produit de contraste (iodé)



Segmentation des coronaires à partir des coupes axiales Challenge ASOCA (Automated Segmentation of Coronary Arteries)

60 examens (30 examens normaux) en orientation axiale


Objectif : Segmentation de l'arborescence des coronaires

Segmentation manuelle des coronaires via le logiciel 3D slicer

Difficulté de la segmentation automatique à cause de :

- La petite taille des coronaires
- La présence d'artefacts
- La prise en compte de l'information 3D


Segmentation des coronaires à partir des coupes axiales (à partir d'un UNET)



Ground Truth

Input CT

Prediction



Discussion

Objectifs

Nécessité de répondre à une problématique précise

Données expertes

Nombre d'examens

➔ Augmentation des données, GAN

Précision et fiabilité de l'expertise

➔ Niveau d'expertise nécessaire ?

➔ Etude de la variation inter et intra-observateur

Efficacité des réseaux de neurones

Réseaux de neurones de type UNet très efficace

➔ Possibilité de prendre un réseau classique et faire du fine tuning

Utilisation possible en routine clinique

➔ S'affranchir des résultats impossibles anatomiquement

➔ Installation possible sur des ordinateurs « classiques »

➔ Explicabilité des résultats

Ethique et propriété intellectuelle

IA et imagerie médicale

Applications à l'imagerie cardiovasculaire

Alain Lalande

alain.lalande@u-bourgogne.fr

