

L'IA qui voit ce que l'œil humain ne peut pas détecter

Deep Learning appliqué au diagnostic médical par imagerie

Pinel Baudelaire T. DAHOUI

Data Scientist & IA | Ingénieur en Travaux Statistiques
tpineldahoui@gmail.com | github.com/Baudelaire12

Lundi 23 Février 2026

Série LinkedIn STEM au Quotidien — Jour 1/40

Plan de la présentation

- 1 Mise en contexte
- 2 Concepts clés
- 3 Développement mathématique
- 4 Cas pratique
- 5 Conclusion
- 6 Références

Un enjeu mondial : le diagnostic médical tardif

Chiffre clé

Selon l'**OMS (2022)**, environ **70%** des décisions médicales reposent sur des résultats d'analyses d'imagerie médicale (radiographies, IRM, scanners).

- Un radiologue expérimenté analyse en moyenne **20 000 à 30 000 images par an** (Rajpurkar et al., 2022).
- Le taux d'erreur diagnostique en radiologie varie entre **3% et 5%** selon les études (Bruno et al., 2015).
- En Afrique subsaharienne, le ratio est de **1 radiologue pour 500 000 habitants** (Mollura et al., 2020).

Question centrale

Comment l'intelligence artificielle peut-elle assister — voire surpasser — l'expertise humaine dans l'analyse d'images médicales ?


Qu'est-ce qu'un réseau de neurones convolutif (CNN) ?

Définition : Un **réseau de neurones convolutif (CNN)** est une architecture de deep learning spécialement conçue pour traiter des données structurées en grille, comme les images.

Principe fondamental :

- 1 **Convolution** : application de filtres pour extraire des caractéristiques locales (bords, textures).
- 2 **Pooling** : réduction de la dimensionnalité tout en conservant l'information essentielle.
- 3 **Classification** : couches entièrement connectées produisant un score de probabilité par classe.

Architecture simplifiée



Transfert learning : apprendre vite avec peu de données

Définition

Le **transfert d'apprentissage** consiste à réutiliser un modèle pré-entraîné sur une grande base de données générale (ex : ImageNet — 14 millions d'images) et à l'adapter à une tâche médicale spécifique.

Modèles de référence utilisés en imagerie médicale :

- **ResNet-50** (He et al., 2016) — détection du cancer du sein
- **DenseNet-121** (Huang et al., 2017) — analyse de radiographies thoraciques (CheXNet)
- **EfficientNet** (Tan & Le, 2019) — classification de pathologies rétinienne
- **Vision Transformer (ViT)** (Dosovitskiy et al., 2021) — segmentation tumorale

Opération de convolution — Formulation mathématique

Définition formelle de la convolution discrète 2D :

$$(I * K)[i, j] = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} I[i + m, j + n] \cdot K[m, n]$$

où :

- I : image d'entrée de taille $H \times W$
- K : filtre (kernel) de taille $M \times N$
- (i, j) : position spatiale dans la carte de caractéristiques (feature map)

Fonction d'activation ReLU :

$$\text{ReLU}(x) = \max(0, x)$$

Fonction Softmax pour la classification multi-classes :

$$P(\text{classe}_k \mid x) = \frac{e^{z_k}}{\sum_{j=1}^K e^{z_j}}$$

où z_k est le score logit associé à la classe k .

Entropie croisée binaire (cas pathologie présente / absente) :

$$\mathcal{L} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{p}_i) + (1 - y_i) \log(1 - \hat{p}_i)]$$

Métriques d'évaluation en imagerie médicale :

Métrique	Formule	Interprétation
Sensibilité	$\frac{VP}{VP+FN}$	Taux de vrais positifs
Spécificité	$\frac{VN}{VN+FP}$	Taux de vrais négatifs
AUC-ROC	$\int_0^1 \text{TPR} d\text{FPR}$	Performance globale
Dice Score	$\frac{2 A \cap B }{ A + B }$	Segmentation

CheXNet : diagnostic de pneumonie sur radiographies

Étude de référence

Rajpurkar et al. (2017) — *CheXNet : Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning* — Stanford University

Données : Base **ChestX-ray14** — 112 120 radiographies, 14 pathologies, 30 805 patients.

Résultats comparatifs :

	CheXNet (IA)	Radiologue humain (moy.)
Score F1 — Pneumonie	0.435	0.387
AUC — Cardiomégalie	0.925	—
AUC — Épanchement pleural	0.936	—
Temps d'analyse / image	< 1 s	3–5 min

Résultat : CheXNet surpasse la performance moyenne de 4 radiologues certifiés sur la détection de pneumonie.

Application africaine : défi et opportunité

Contexte béninois et africain

En Afrique de l'Ouest, le manque de spécialistes rend l'IA particulièrement stratégique pour le diagnostic (Mollura et al., 2020).

Initiatives concrètes :

- **Projet ARMMAN (Inde, étendu Afrique)** : IA pour le suivi des grossesses à risque via des données vocales.
- **Google Health Africa** : détection de la rétinopathie diabétique au Ghana et en Thaïlande (Gulshan et al., 2016).
- **MSF & IA** : analyse automatisée de radiographies pour le dépistage de la tuberculose en zones de conflit.

Verrous à lever : qualité des données locales, infrastructure numérique, formation des personnels de santé.

Synthèse

Le deep learning, et en particulier les CNN, transforment radicalement le diagnostic médical par imagerie. Ils permettent une analyse rapide, reproductible et à faible coût, avec des performances comparables ou supérieures à l'expertise humaine sur des tâches spécifiques.

Perspectives :

- Généralisation aux pays à faibles ressources via des modèles légers (TinyML, Edge AI)
- Développement de modèles explicables pour gagner la confiance des cliniciens
- Constitution de bases de données africaines annotées pour des modèles adaptés localement
- Intégration dans des applications mobiles utilisables sans connexion internet

« L'IA ne remplacera pas les médecins. Mais les médecins qui utilisent l'IA remplaceront ceux qui ne l'utilisent pas. »

— Eric Topol, *Deep Medicine*, 2019

Références bibliographiques

-  Rajpurkar, P., Irvin, J., Ball, R. L., et al. (2017). *CheXNet : Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning*. arXiv :1711.05225.
-  He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *CVPR*, 770–778.
-  Gulshan, V., Peng, L., Coram, M., et al. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy. *JAMA*, 316(22), 2402–2410.
-  Mollura, D. J., Lungren, M. P., et al. (2020). Radiology & global health. *Radiology*, 295(3), 547–554.
-  Bruno, M. A., Walker, E. A., & Abujudeh, H. H. (2015). Understanding and confronting our mistakes. *RadioGraphics*, 35(6), 1668–1676.
-  World Health Organization. (2022). *Global Health Observatory — Diagnostic Imaging*. WHO Press.
-  Topol, E. J. (2019). *Deep Medicine : How Artificial Intelligence Can Make Healthcare Human Again*. Basic Books.

Merci pour votre attention

Pinel Baudelaire T. DAHOUI

Data Scientist & IA | Ingénieur en Travaux Statistiques

`tpineldahoui@gmail.com`

`github.com/Baudelaire12`

LinkedIn : @Pinel Baudelaire DAHOUI

Série STEM au Quotidien — 40 jours