

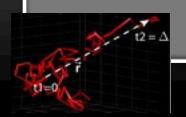


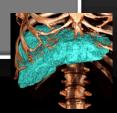


Intelligence Artificielle et Tumeurs Hépatiques

Philippe Soyer

Radiologie Viscérale, HUPC, Cochin









Prolifération d'études scientifiques consacrées à l'IA dans le domaine des tumeurs hépatiques.

Trois domaines majeurs

Annotation des données

Machine learning

Radiomique

Annotation des données



AI est habituellement effectuée au moyen d'un apprentissage supervisé.

Les données sont fournies avec un « ground truth ».

Les annotations dépendent du problème (normal vs. anormal; délimitation exacte de l'anomalie).

Annotation des données



Contourage

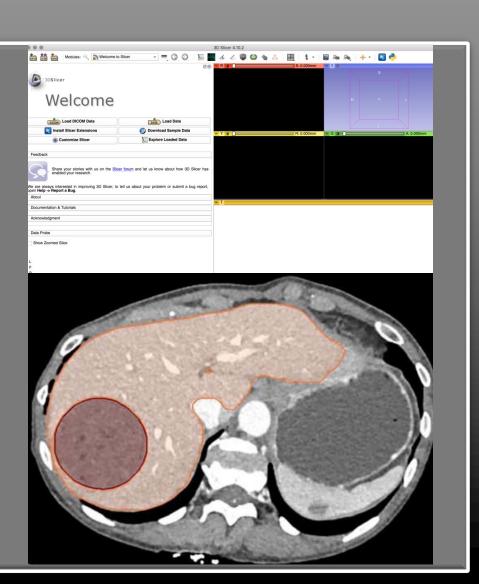
Logiciels

3D slicer

Velocity

IKT-SNAP

DICOM data



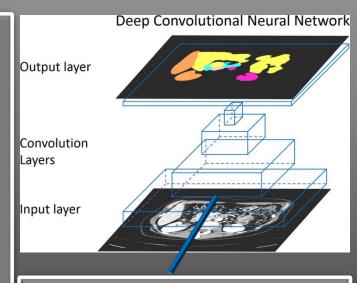
Machine learning



Le but est d'automatiser le fait d'obtenir un résultat «y» à partir de données «x»

Apprentissage supervisé fondée sur des données «x» annotées «y» par un ou des observateurs

L'algorithme est entrainé à trouver les caractéristiques permettant d'arriver à «y» à partir d'un set d'apprentissage (deep convolutional neural network)

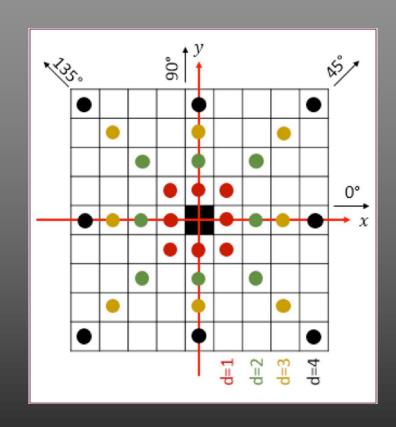


Hidden layers of interconnected convolution layers where the output of 1 layer becomes the input of the next layer, to generate the final output layer.



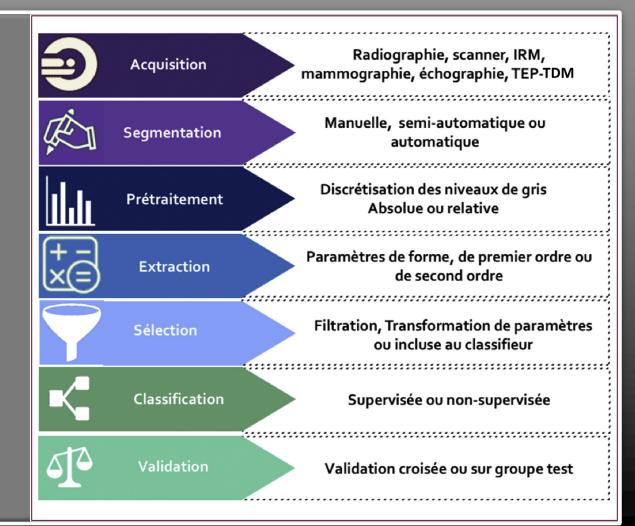
Images radiologiques contiennent une immense quantité de données non visibles à l'œil nu.

Le concept est d'utiliser ces données qui sont représentatives de l'hétérogénéité tissulaire (biomarqueurs).



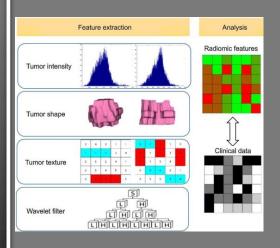


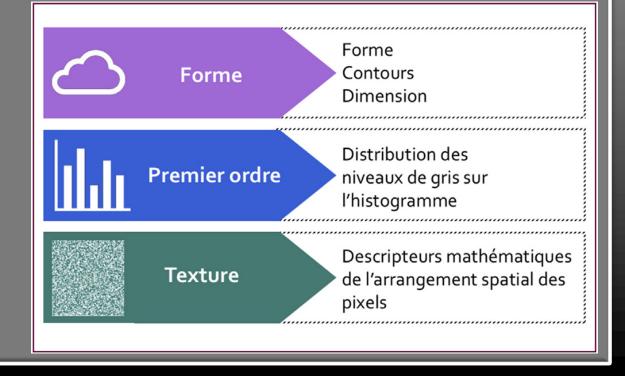
Sept étapes





Extraction Différents paramètres







Extraction

Paramètres de forme (shape; contours, forme et dimensions d'une lésion en 2D ou 3D.

Paramètres de premier ordre (first order; distribution d'intensité des niveaux de gris des pi/voxels (histogramme)

Paramètres de texture (second order)

Organisation spatiale des pixels (matrice de co-occurrence des niveaux de gris (grey-level cooccurrence matrix [GLCM])

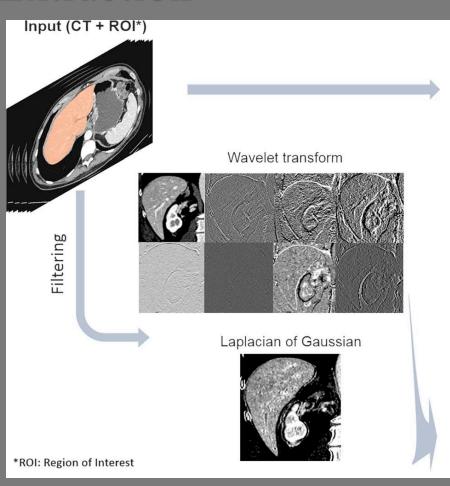
Taille des zones homogènes de niveaux de gris (grey-level size zone matrix [GLSZM]

Différence des niveaux de gris de voisinage (neighborhood grey-tone difference matrix, [NGTDM])

Longueur de plages de niveau de gris (grey-level run length matrix [GLRLM])



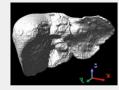
Extraction



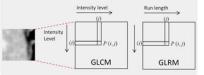
Feature Extraction

For the original volume
First order statistics

Shape features



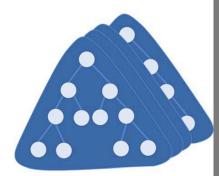
Texture features



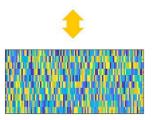
For each filtered volume

First order statistics
Texture features

Classification



Random Forest (or other classifiers)



Clinical outcomes



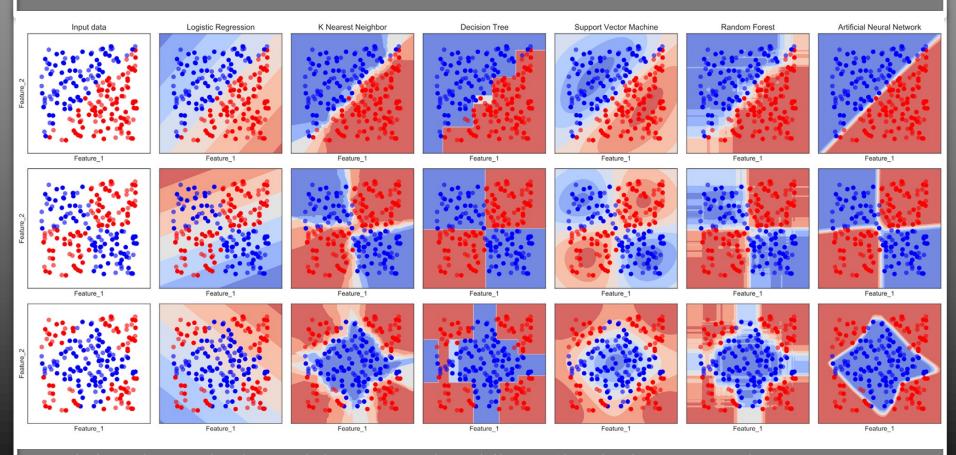
Classification

Les méthodes de classification ont pour but d'entraîner un algorithme permettant d'identifier l'appartenance ou non d'une lésion à un groupe (bénigne ou maligne) en réalisant des prédictions à partir d'un grand nombre de données.

Classification supervisée ou non supervisée



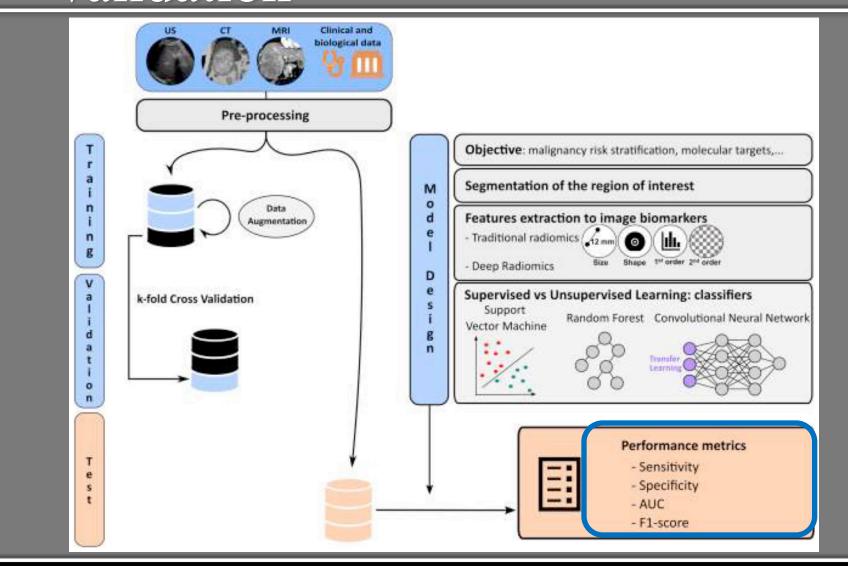
Classification



Decision boundaries with 6 ML classifiers (logistic regression, K nearest neighbor, decision tree, SVM, RFand artificial neural network)



Validation



Intelligence artificielle



Applications

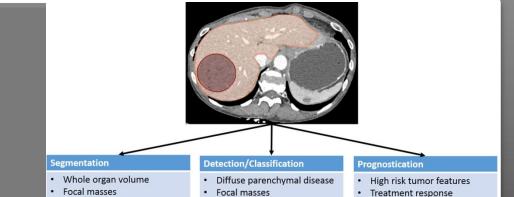
Echographie, TDM, IRM

Détection tumorale

Caractérisation masse focale

Prédiction du risque (MVI)

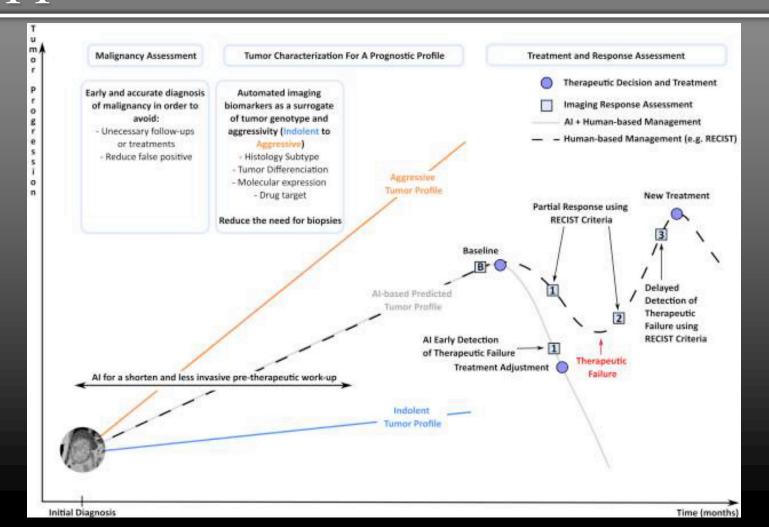
Prédiction de la réponse au traitement (chirurgie, traitement loco-régional, traitement systémique)



Intelligence artificielle



Applications



Applications cliniques-HCC Université de Paris



Clinical Problem	Imaging Modality	Machine Learning Technique	Validation	Accuracy or AUC of Best Model	Ref
Staging of liver fibrosis*	CT	Radiomics	None	AUC, 0.87	28
	CT	Radiomics	None	AUC, 0.86	29
	CT	Deep learning	External	AUC, 0.95	30
	MRI	Radiomics	Split sample	AUC, 0.87	31
	MRI	Deep learning	Split sample	AUC, 0.84	32
	US	Deep learning	External	AUC, 0.90	33
	US elastography	Radiomics and deep learning	External	AUC, 0.97	34
Classification of focal liver masses	CT	Radiomics	Cross validation	84.9	35
	CT	Radiomics	None	AUC, 0.824	36
	CT	Radiomics	Split sample	AUC, 0.865	37
	CT	Deep learning	Split sample	AUC, 0.84	38
	MRI	Radiomics	None	96.4	39
	MRI	Radiomics	Split sample	AUC, 0.89	40
	MRI	Deep learning	Split sample	90.0	41
	MRI	Deep learning	Split sample	AUC, 0.94	42
	US	Radiomics	Cross validation	AUC, 0.94	43
	US	Deep learning	External	AUC, 0.891	44
	US	Deep learning	Split sample	84.0	45
Prediction of MVI in HCC	Contrast enhanced US	Radiomics	Split sample	AUC, 0.731	46
	CT	Radiomics	Split sample	AUC, 0.844	47
	CT	Radiomics	Split sample	AUC, 0.819	48
	CT	Radiomics	Split sample	AUC, 0.793	49
	MRI	Radiomics	Split sample	AUC, 0.83	50
	MRI	Radiomics	Split sample	AUC, 0.822	51
Prediction of CK19 expression in HCC	MRI	Radiomics	Cross validation	AUC, 0.765	52
Prediction of HCC recurrence after curative therapy	CT	Radiomics	Cross validation	AUC, 0.817	53
	CT	Radiomics	External	C-index, 0.82	54
	MRI	Radiomics	Split sample	C-index, 0.679	55
	CT	Radiomics	Split sample	AUC, 0.79	56
	CT	Radiomics	Split sample	C-index, 0.736	57
	CT	Radiomics	Split sample	C-index, 0.705	58
Prediction of HCC treatment response after TACE	CT	Deep learning	External	85.1	59
	MRI	Radiomics	Split sample	C-index, 0.727	60
	MRI	Radiomics	Split sample	AUC, 0.800	61
	Contrast enhanced US	Radiomics and deep learning	Split sample	AUC, 0.93	62

Chu LC et al. Current status of radiomics and deep learning in liver imaging. J Comput Assist Tomogr 2021; 45:343-351.



Détection de nouvelles lésions sur TDM de suivi (taux de VP = 86%)*

Déterminer l'origine des métastases hépatiques (mélanome, CCR, pancréas, sein) (56% d'exactitude)†

Distinguer entre lésions bénignes et malignes en échographie (90% d'exactitude)‡

^{*}Vivanti R, et al. Int J Comput Assist Radiol Surg 2017

[†]Ben-Cohen A et al. Acad Radiol 2017

[‡] Guo LH et al. Clin Hemorheol Microcirc 2018

Classification des tumeurs hépatiques

Plusieurs études ont rapporté des exactitudes plus élevées pour les modèles d'IA en comparaison de l'interprétation des radiologues

Results Our model trained on the complete set of all lesions achieved a test accuracy of 0.84 (95% CI 0.74–0.90) compared to expert 1 with a test accuracy of 0.80 (95% CI 0.70–0.87) and expert 2 with a test accuracy of 0.73 (95% CI 0.63–0.82). Our model trained on the uncertain set of lesions achieved a test accuracy of 0.79 (95% CI 0.69–0.87) compared to expert 1 with a test accuracy of 0.70 (95% CI 0.59–0.78) and expert 2 with a test accuracy of 0.66 (95% CI 0.55–0.75). On the uncertain dataset, compared to all experts averaged, the model had higher test accuracy (0.79 vs. 0.68, p=0.025). **ECHO** Conclusion Deep learning algorithms proposed in the current study improve differentiation of benign from malignant ultrasound-captured solid liver lesions and perform comparably to expert radiologists. Deep learning tools can potentially be used to improve the accuracy and efficiency of clinical workflows.



Classification des tumeurs hépatiques

Plusieurs études ont rapporté des exactitudes plus élevées pour les modèles d'IA en comparaison de l'interprétation des radiologues

Results: The random-forest model successfully distinguished the 3 lesion types and normal liver with predicted classification performance accuracy for 91.2% for adenoma, 94.4% for focal nodular hyperplasia, and 98.6% for hepatocellular carcinoma. This error prediction was generated using a subset of data points not used in generation of the model, but not on discrete prospective cases. In contrast, the 2 human readers using the same image series data analyzed by the CTTA software had lower accuracies, of 72.2% and 65.6%, respectively. The explicit regression model with a subset of image parameters had intermediate overall accuracy of 84.9%.



Prédire la réponse au traitement

HCC et TACE (modèle clinique et IRM, 78% exactitude)*

Métastases de CCR et FOLFIRI-Bevacizumab en première ligne † (modèle radiomique et TDM à 2 mois prédit l'OS aussi bien que le RECIST à 6 mois)

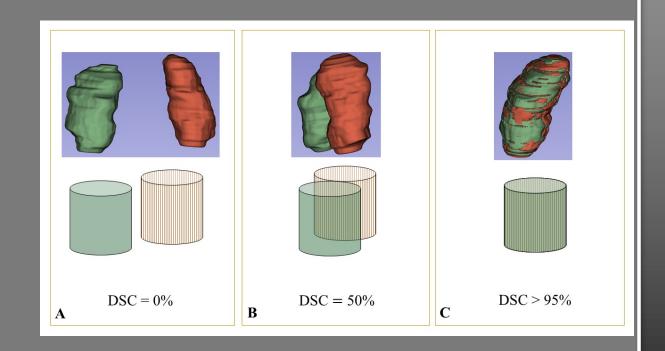
^{*}Abajian, et al. Vasc Interv Radiol 2018

[†]Dohan A et al. Gut 2017



Segmentation automatique de tumeurs hépatiques

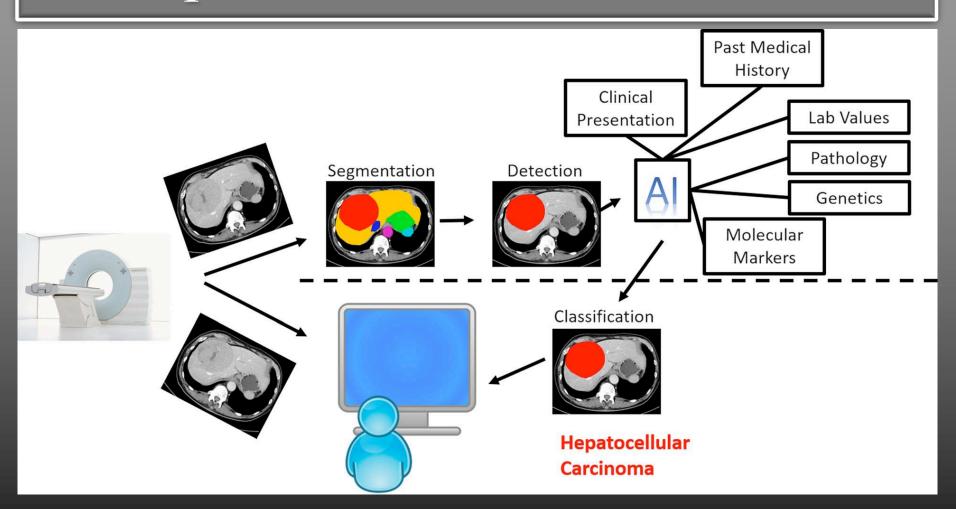
DSC 66% - 83%



- *Li W et al. J Comput Commun 2015
- † Chen Y et al. Front Genet 2019
- ‡ Linguraru MG et al. IEEE Trans Med Imaging 2012

Perspectives









En 2016, Geoffrey Hinton écrivait "We should stop training radiologists now. It's just completely obvious within five years that deep learning is going to do better than radiologists."

