

Utilisation du machine learning en imagerie radio-isotopique per-opératoire



Françoise Bouvet
IMNC – CNRS

- Contexte
- Données
- Réseaux de neurones
- Phase d'apprentissage
- Résultats
- Outils
- Conclusion et perspectives

Création : 2006

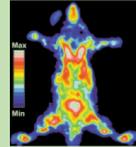
Effectifs : ~40

Tutelles : CNRS , Paris Sud, Paris Diderot

• Imagerie Biophotonique In Vivo

- Imageries et spectroscopie à l'échelle cellulaire
- Imagerie multimodale en champ large
- Caractérisation des propriétés optiques des tissus sains et pathologiques

IBIV



IRIC

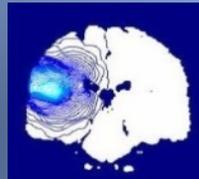


• Instrumentation et imagerie radio-isotopique clinique et préclinique

- Imagerie du petit animal vigile
- Imagerie clinique : imagerie per-opératoire et imagerie ambulatoire pour le suivi thérapeutique, thérapie par radionucléides
- Nouvelles approches instrumentales

ST

MSB



• Modélisation

- Modèles de croissance de gliomes de bas grade sur biopsies, modélisation de l'action des traitements
- Modélisation systèmes biologiques : croissance tumorale...
- Etude systèmes dynamiques

NARA



• Nouvelles approches en radiothérapie

- Nouvelles approches dépôt de dose
- Optimisation techniques de RT conventionnel (nanoparticules, dose painting,...)
- Dosimétrie dans des conditions non standard.
- Radiobiologie autour des nouvelles techniques de RT



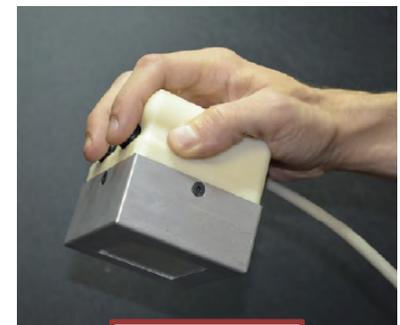
- Imagerie nucléaire peropératoire
- Conception de camera miniature pour l'imagerie γ et β
- Développement de nouvelle génération à base de SiPM



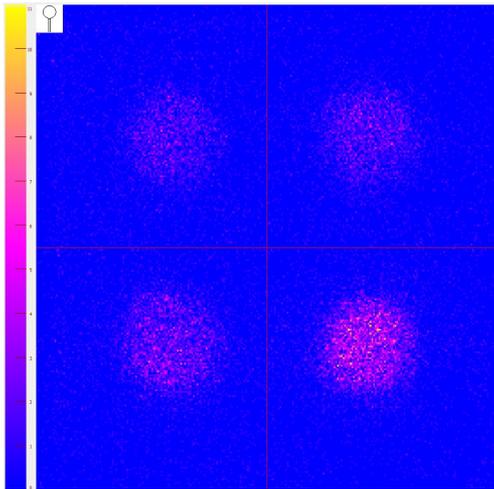
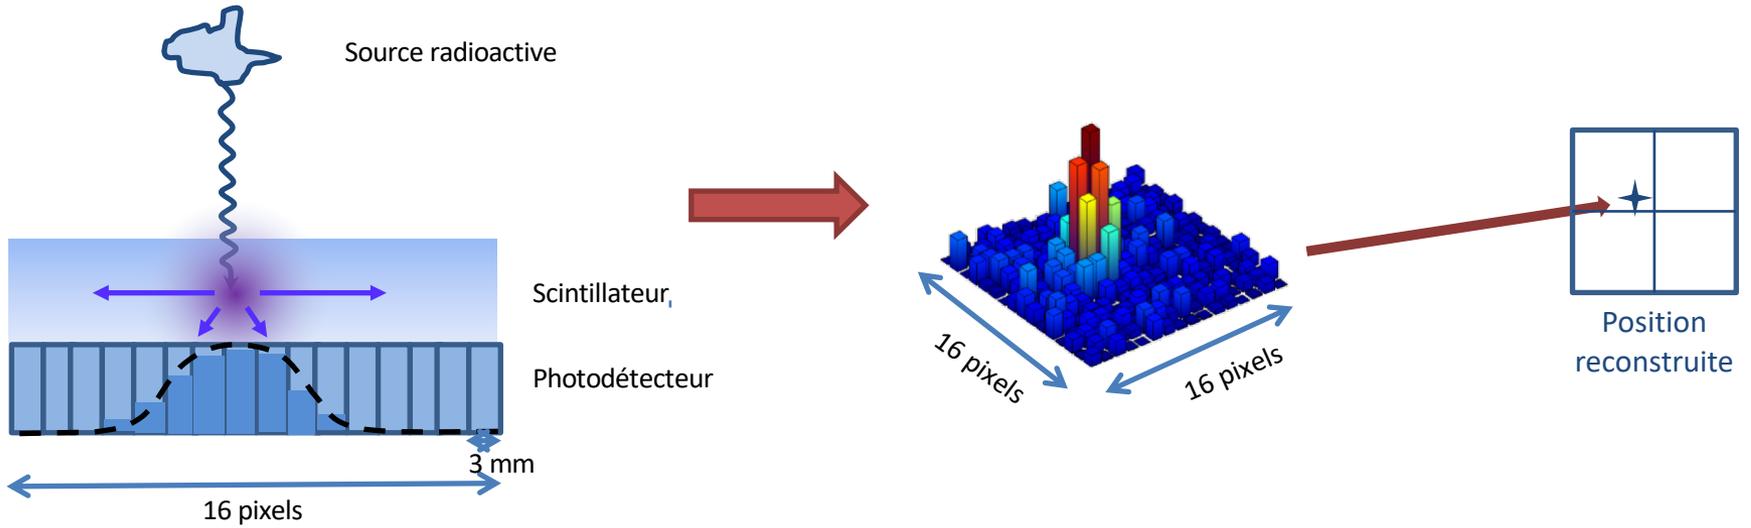
POCI



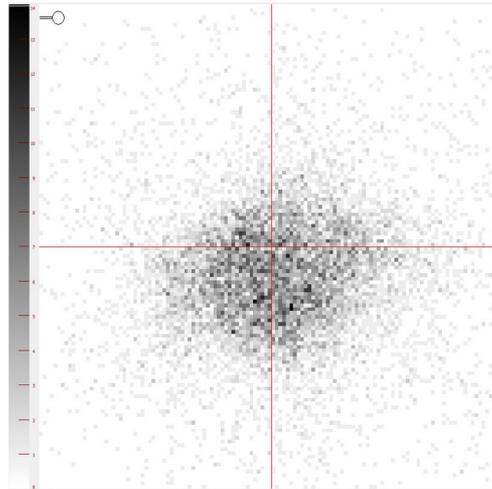
TReCam



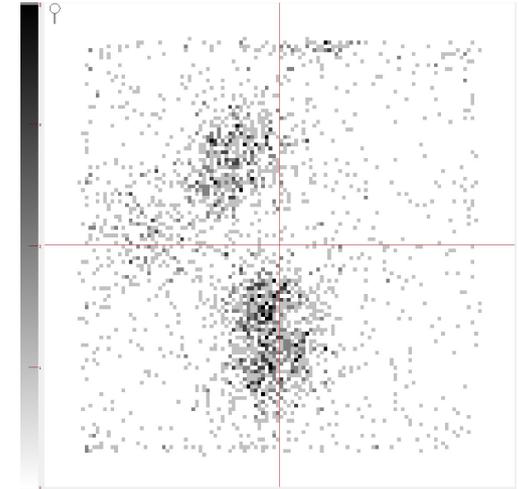
MAGICS



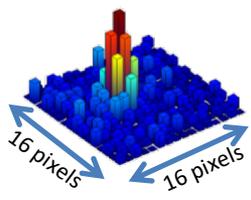
Puits de radioactivité



Ganglion



Deux ganglions

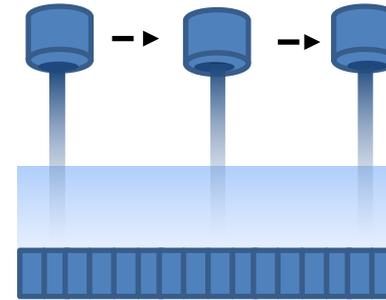


Non supervisées
Supervisée

Méthodes	Reconstruction temps réel	Précision	Mise en œuvre
Barycentre	😊😊	😞😞	😊😊
Modèle de Scrimger-Baker Méthode itérative de Levenberg-Marquardt	😞	😊	😊
Réseaux de neurones	😊	😊	😐

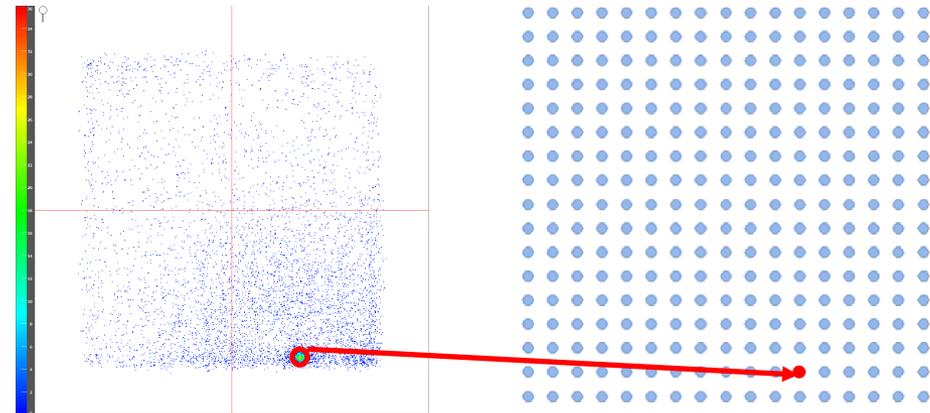
➤ Scan du détecteur

- Scintillateur $CeBr3$ - 6 mm
- Source collimatée de ^{133}Ba
- γ de 360 keV
- Pas de 3 mm \rightarrow 17*17 positions
- Acquisition de 30 min / position
- ~ 45000 interactions / position



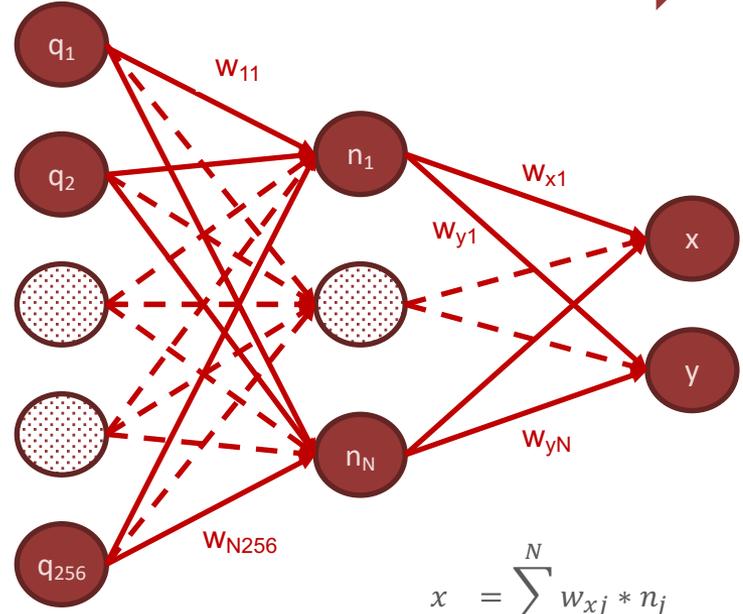
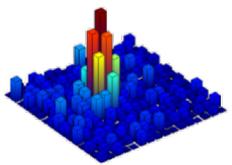
Sélection des interactions (événements) :

- ~ 8000 après sélection en énergie
- Reconstruction par barycentre
- ~ 3000 pour la base de données (apprentissage / validation / test)



➤ Irradiation uniforme du détecteur sans collimateur

- 500 fichiers de 5 min

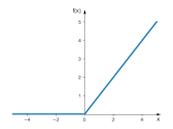
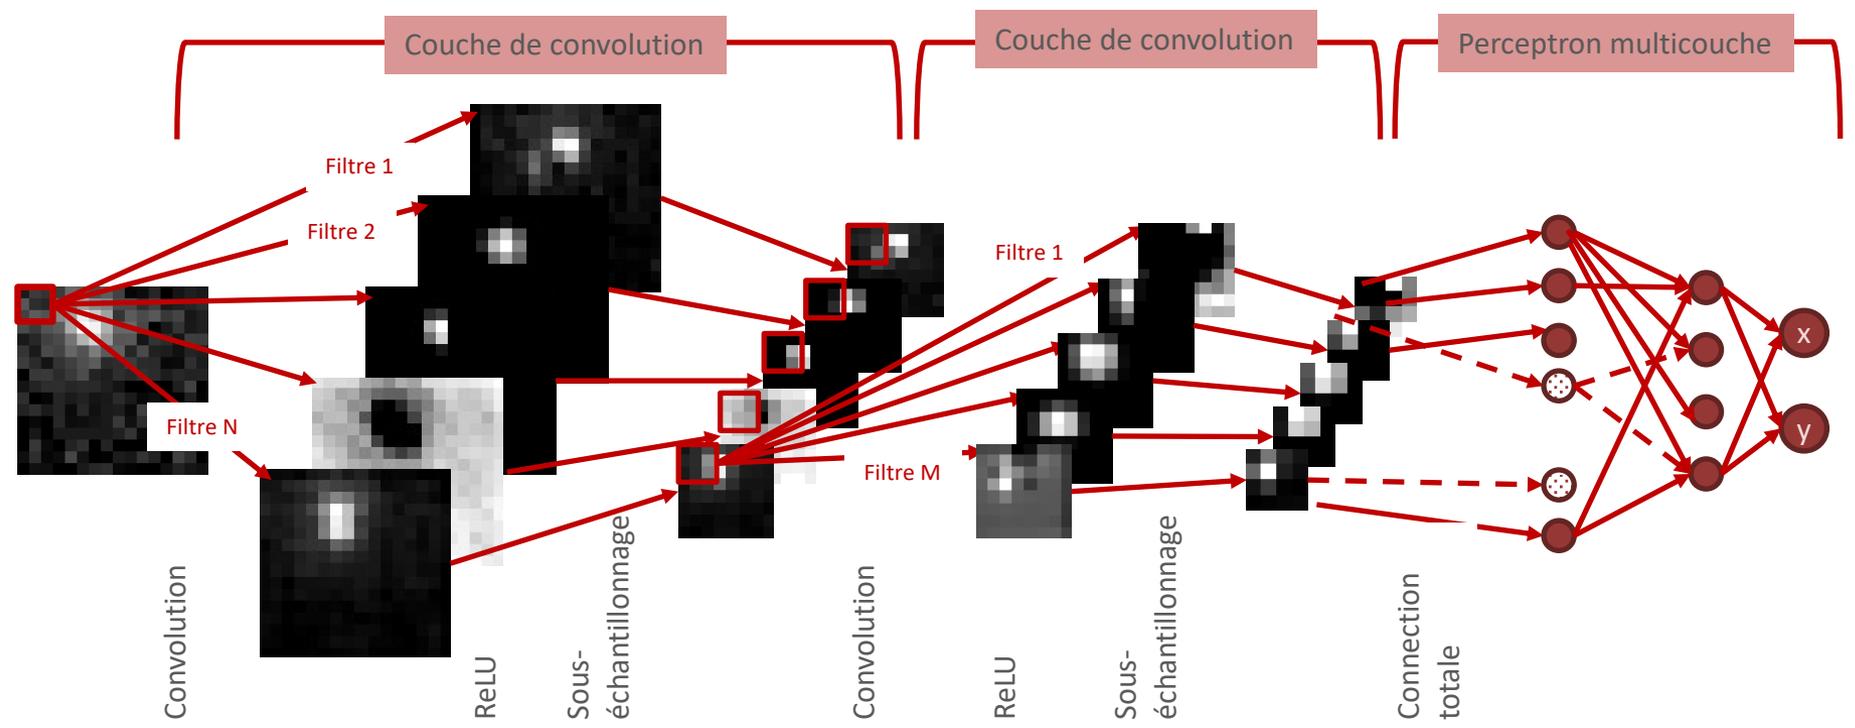


$$n_i = f\left(\sum_{j=1}^{256} w_{ij} * q_j\right)$$

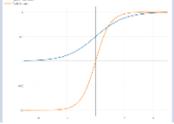
$$x = \sum_{j=1}^N w_{xj} * n_j$$
$$y = \sum_{j=1}^N w_{yj} * n_j$$

- f : fonction d'activation
- N : nombre de neurones dans la couche cachée
- W_{ij} : poids des connexions





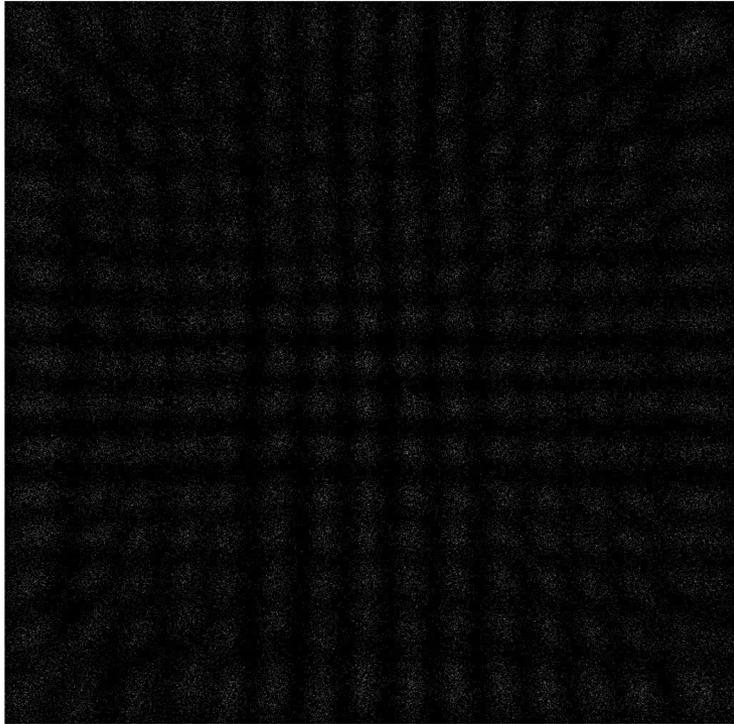
Réseau multi-couches

Fonction d'activation couches intermédiaires	sigmoïde tanh	
Dernière couche	Linéaire	
Nombre de couches cachées	1 - 2	
Nb neurones / couche cachée	4 – 256	
Optimisation	rmsprop, adamax, adam sgd, adagrad, adadelata	
Nb échantillons d'apprentissage	400	
Validation	20%	
Learning rate	0,5	
Fonction de perte	Mean-square-error	

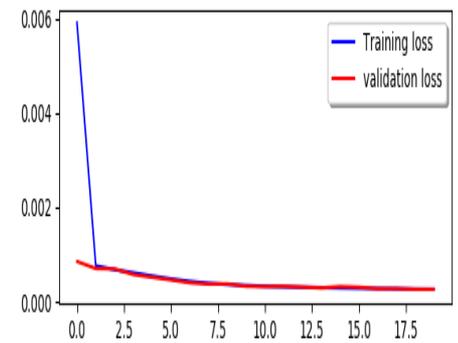
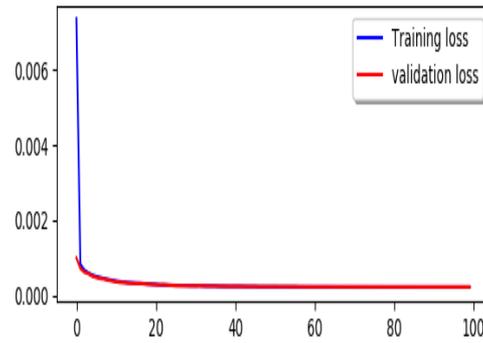
Réseau de convolution

Nombre de couches de convolution	1 - 2
Nombre de filtres	4-64
Taille des noyaux de convolution	(3, 3) (5, 5)
Sous-échantillonnage - pas	max (moy) - 2
Fonction d'activation	ReLU
Padding (remplissage des bords)	same
Dropout	non

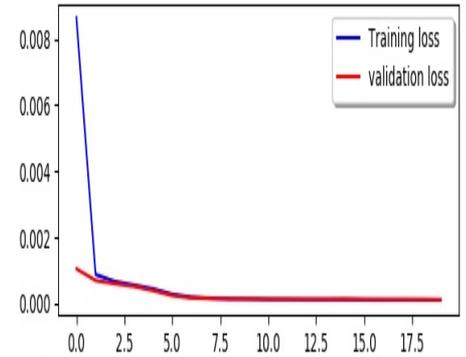
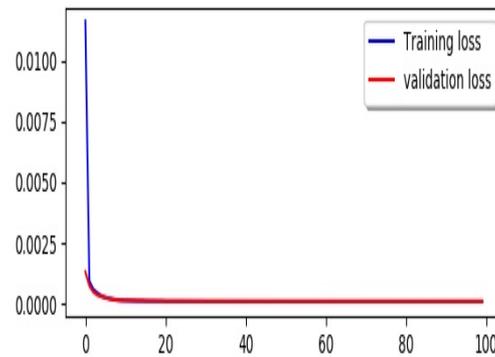
Paramètres du réseau multi-couches



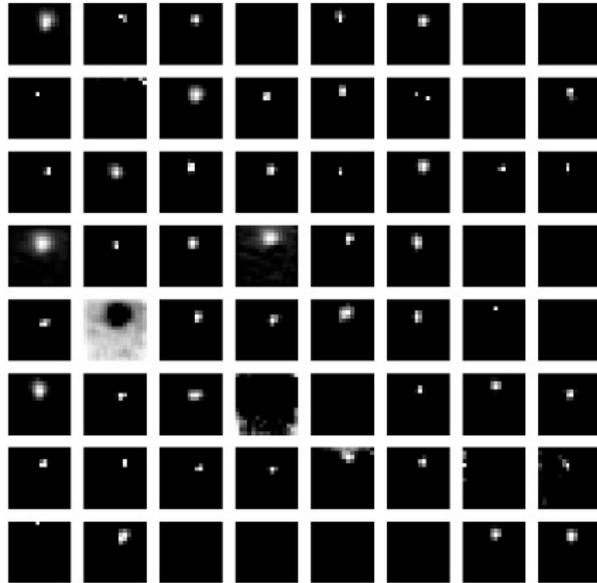
Fonction de perte / nombre d'époques



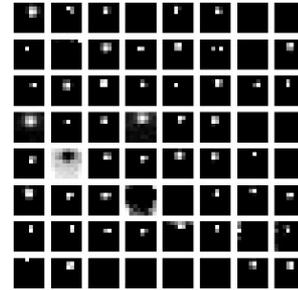
Réseau multi-couches



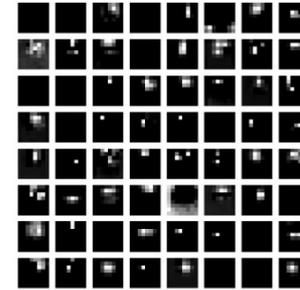
Réseau de convolution



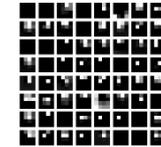
Première couche de convolution – 64 filtres



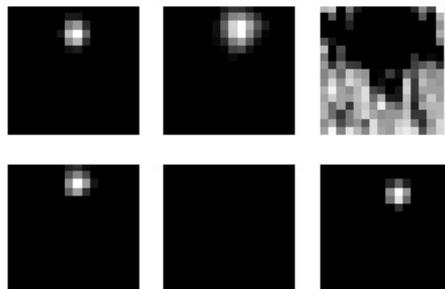
Sous-échantillonnage



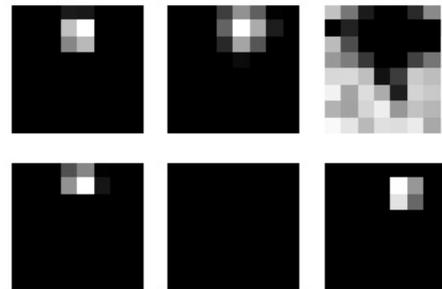
Seconde couche de convolution – 64 filtres



Sous-échantillonnage



1 couche de convolution – 6 filtres

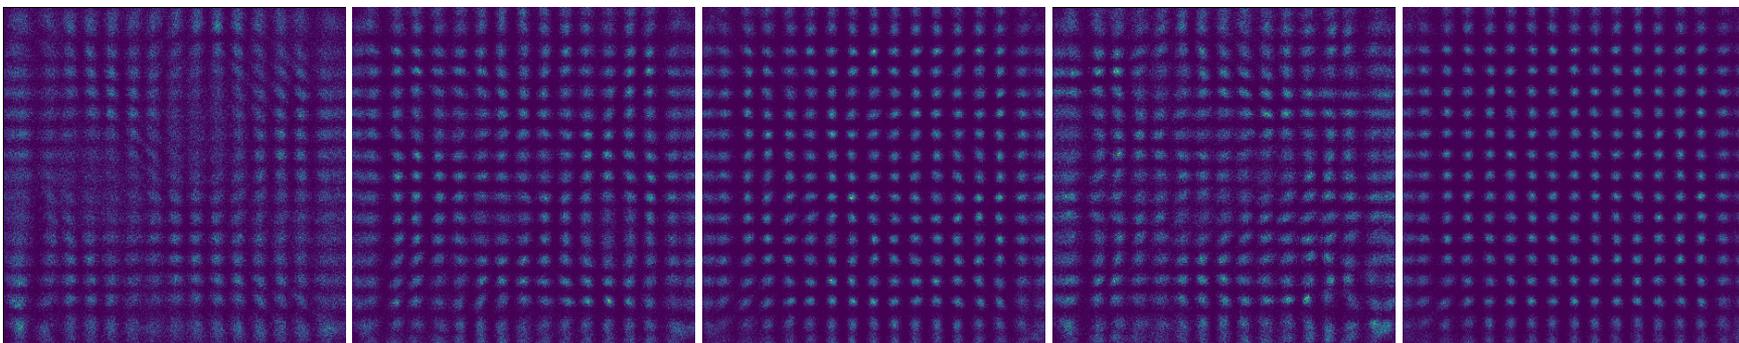


Sous-échantillonnage

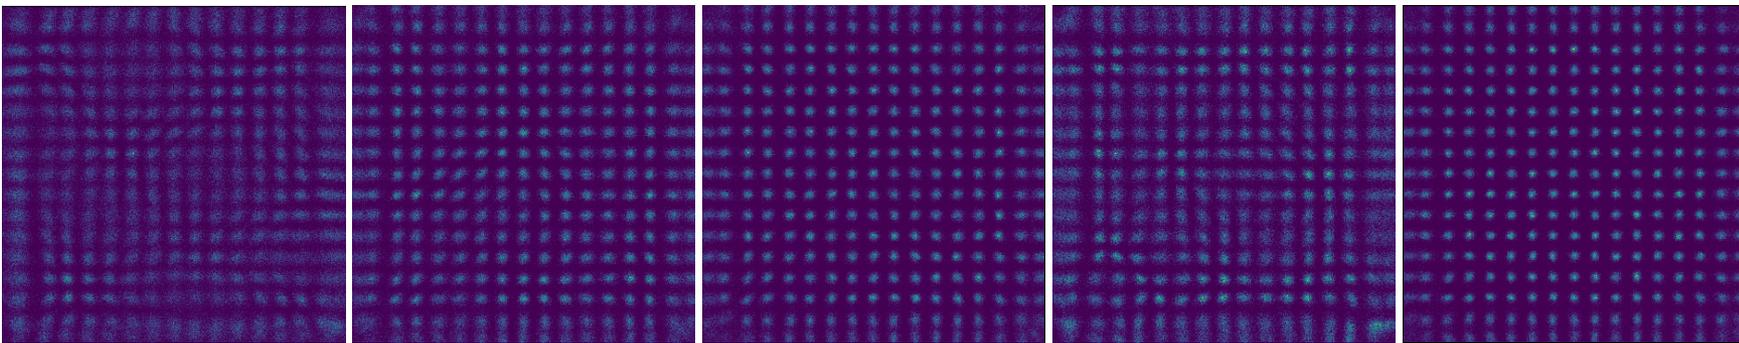
Résultats spots – réseaux multi-couches

Echantillon test – 100 epochs

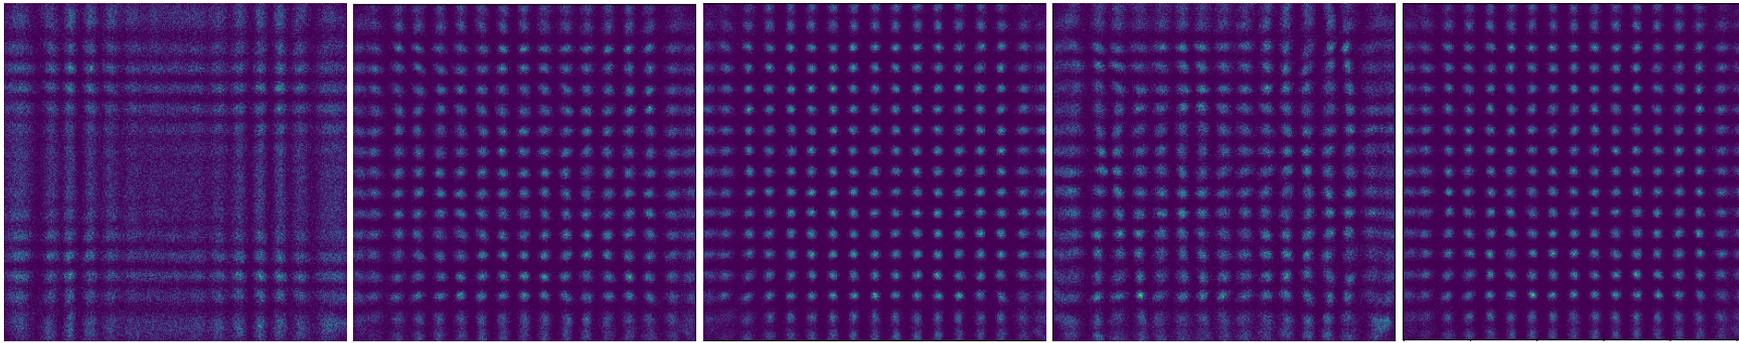
adamax



rmsprop



adam



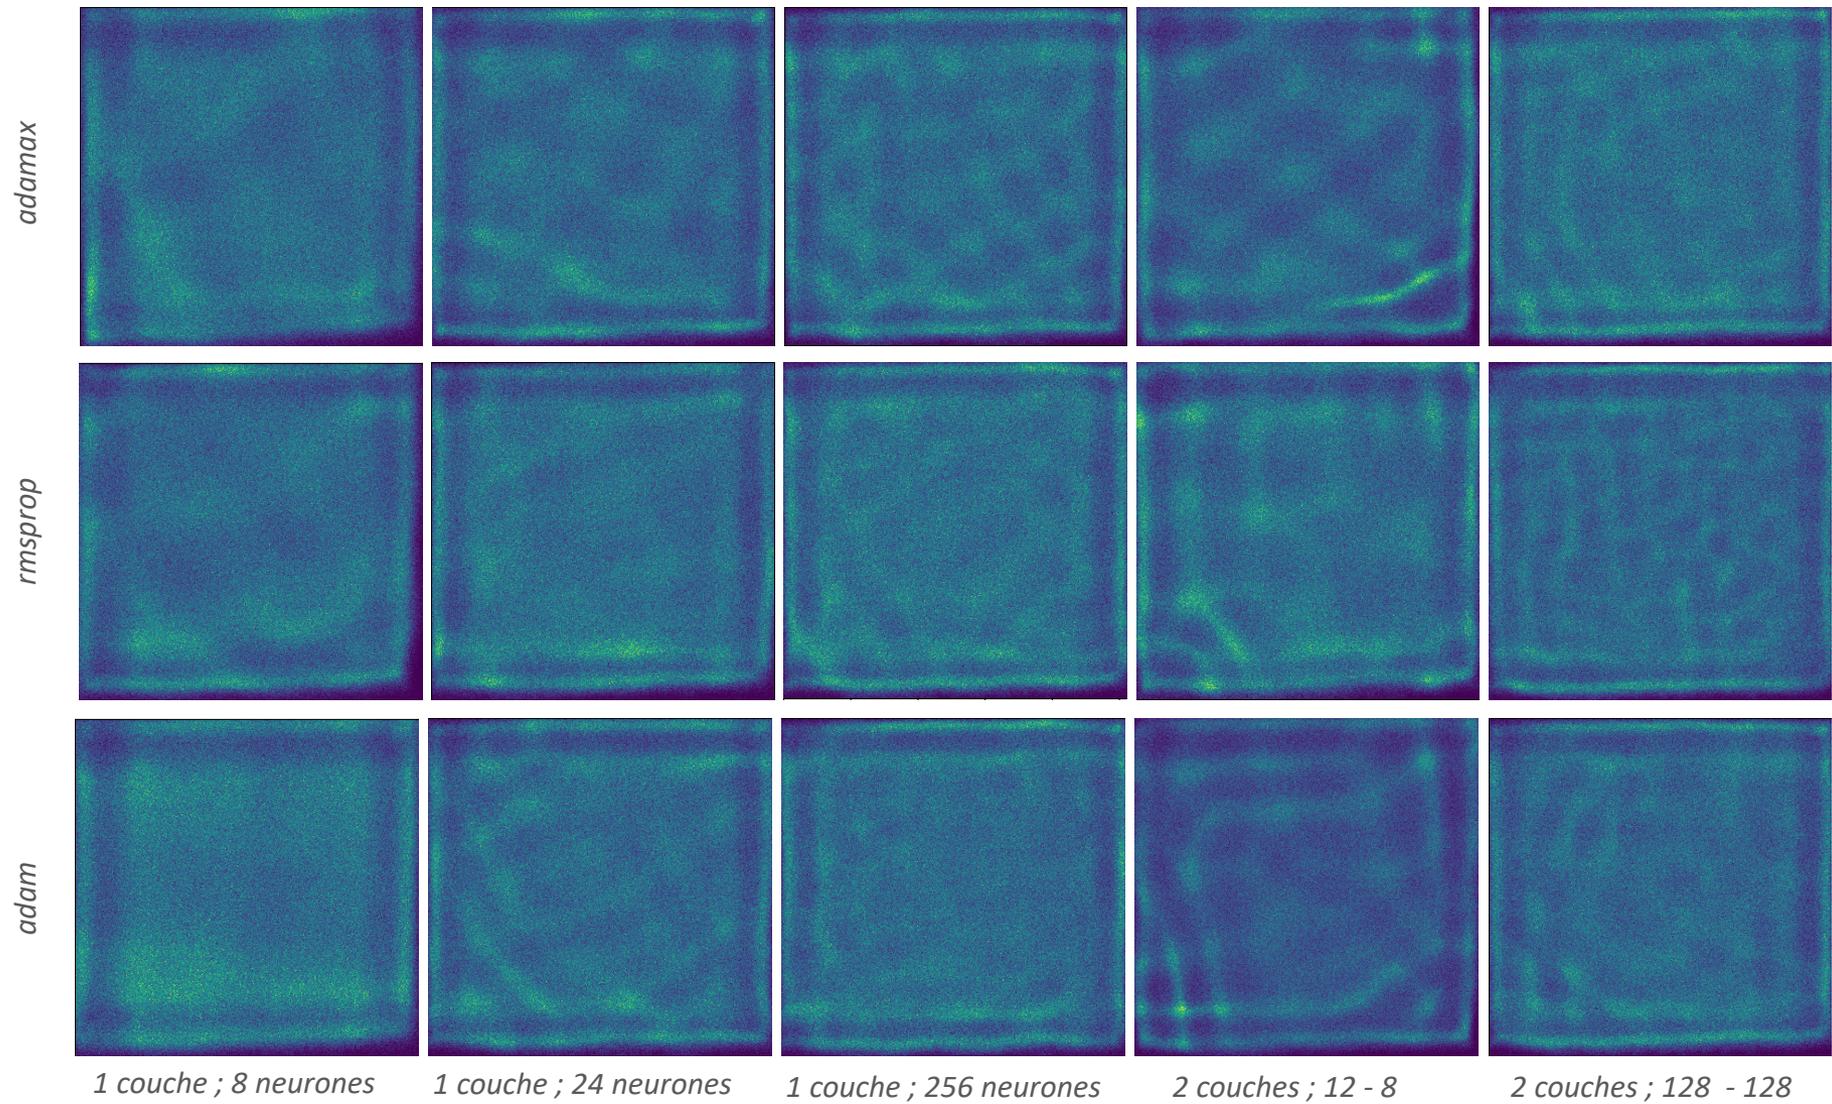
1 couche ; 8 neurones

1 couche ; 24 neurones

1 couche ; 256 neurones

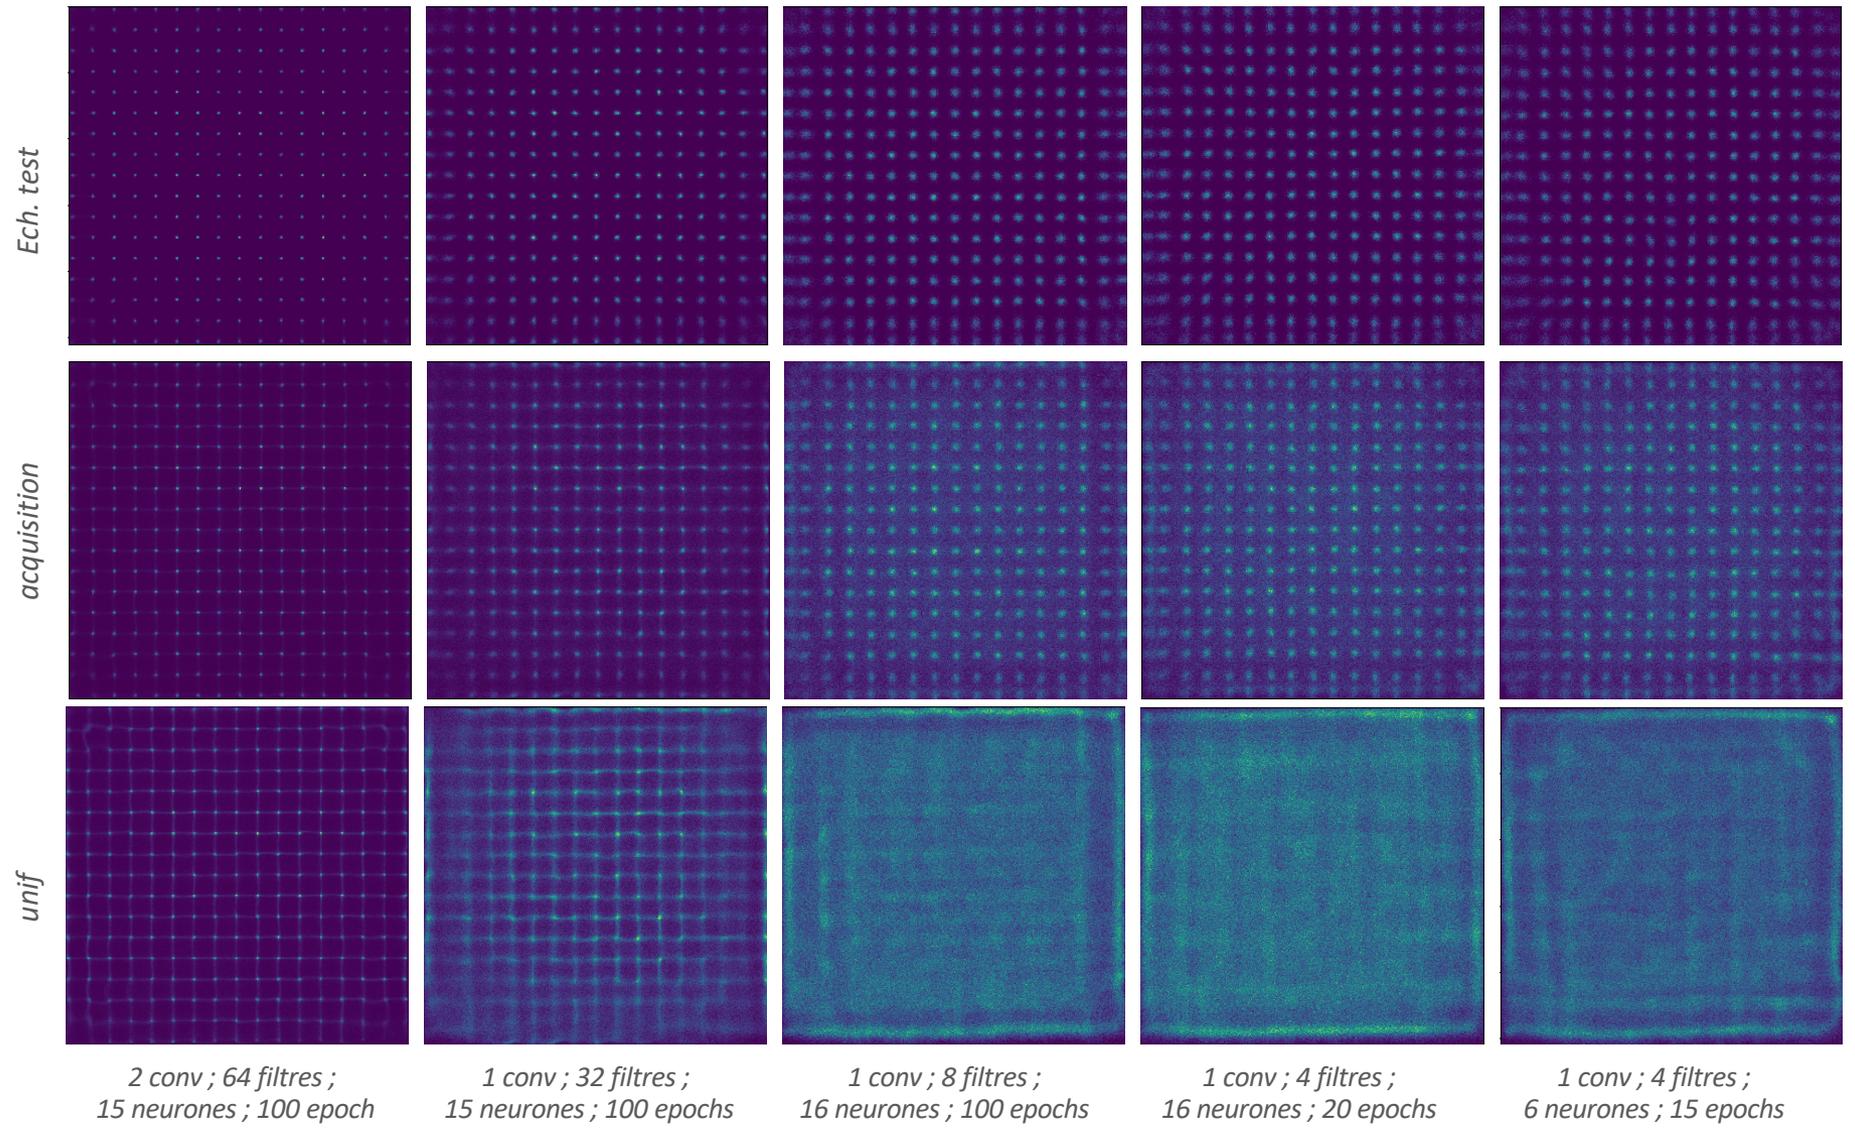
2 couches ; 12 - 8

2 couches ; 128 - 128



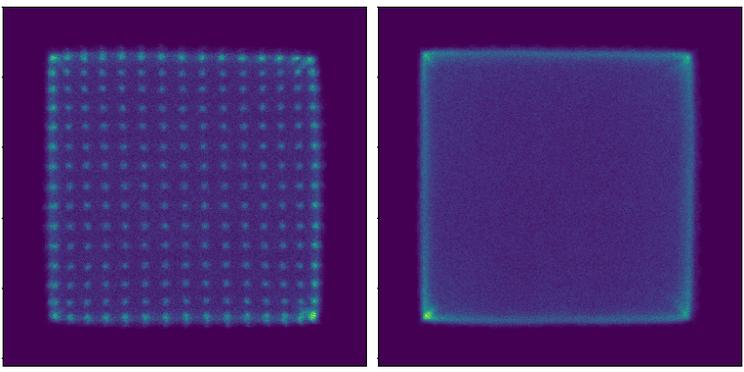
Résultats spots – réseaux de convolution

Réseau de convolution – 400 ech app. / position - adamax

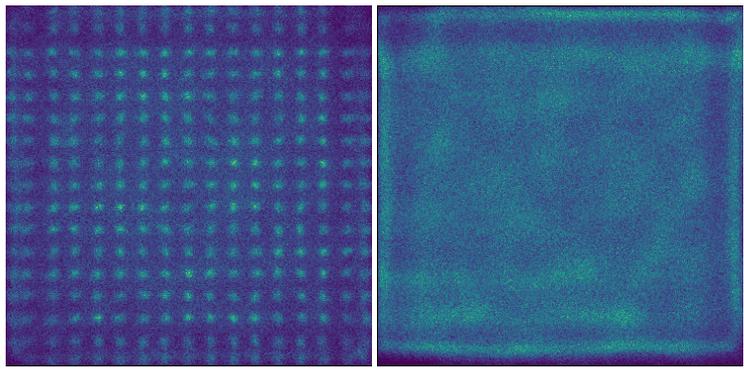


Résultats – comparaison

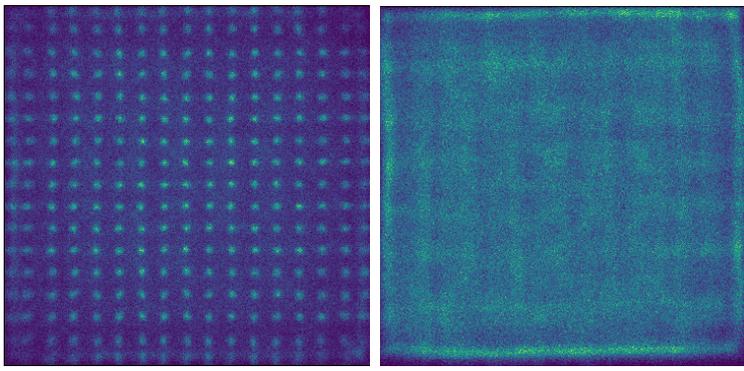
Barycentre



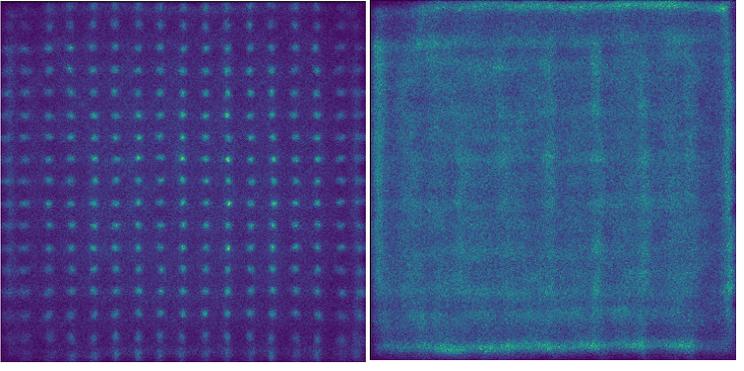
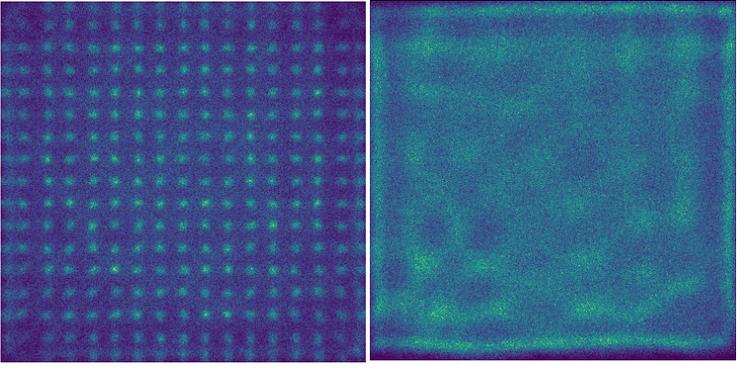
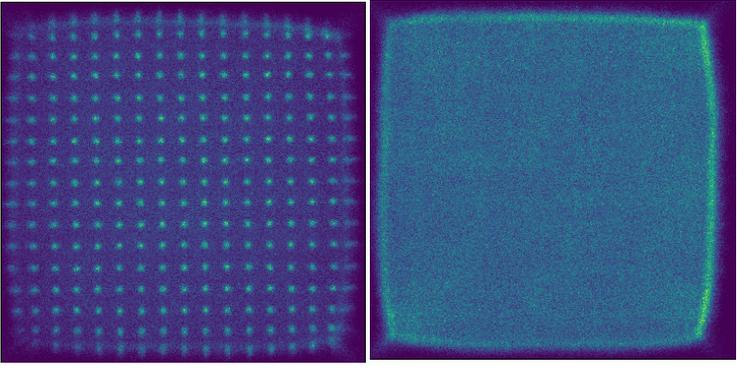
1 couche cachée ; 64 neurones



adamax ; 16 neurones



Multi-couches
adamax
sigmoïde
100 epochs



Levenberg Marquart

2 couches cachées
64 neurones /couche

rmsprop ; 12 neurones

FANN Fast Artificial Neural Network

FANN Fast Artificial Neural Network Library

- C++
- réseaux multicouches
- plus main

C++

Qt

KERAS : librairie

- version init
- interface (
- python, R
- open source
- interfaçabl
- supporte le
- mult
- conv
- récu
- fonctionne

```
from keras.models import Sequential
from keras.layers import Dense

model = Sequential()

model.add(Dense(units=64, activation='sigmoid', input_dim=100))
model.add(Dense(units=10, activation='softmax'))

model.compile(loss='categorical_crossentropy',
              optimizer='adamax',
              metrics=['accuracy'])

model.fit(x_train, y_train, epochs=5, batch_size=32)

loss_and_metrics = model.evaluate(x_test, y_test, batch_size=128)

classes = model.predict(x_test, batch_size=128)
```

Keras

Soutenu par une large communauté (630 contributeurs sur Github)

Pérennité : utilisé par Netflix, Uber, Google, la NASA

Lwttnn : réseaux keras -> C++

- Réseaux de convolution très puissants -> risque de surapprentissage
- Apprentissage plus homogène avec les réseaux de convolution / multi-couches
- Paramètres les plus influents
 - Taille du réseau (nombre de couches, nombre de filtres, nombre de neurones)
 - Taille du filtre, padding
- Algorithmes d'optimisation : adamax, adam, rmsprop équivalents

- Evaluation quantitative des résultats (unif, spots)
- Transfert dans logiciel d'acquisition C++ : performances
- Application à d'autres scintillateurs et d'autres radioisotopes