

Retour sur l'AG 2025 du réseau semi-conducteurs de l'IN2P3

Jocelyn Domange

LP2I Bordeaux – 16 octobre 2025


Journées 2025 du réseau SC

- Le réseau "R & D instrumentation" dédié aux détecteurs semi-conducteurs (IN2P3-IRFU) a été créé en 2012 dans le but de promouvoir les échanges entre les différents laboratoires actifs dans le domaine
- Journées organisées cette année les 1 et 2 juillet 2025 au LP2I Bordeaux
- Thématique 2025 : l'intelligence artificielle appliquée aux détecteurs semi-conducteurs.
- Les présentations sont accessibles sur la page Indico :
<https://indico.in2p3.fr/event/36113/>

Spectroscopie gamma avec AGATA

Présentation de Jérémie Dudouet, IP2I Lyon


- AGATA se compose de 50 détecteurs en HPGe (180 sont prévus pour compléter la sphère), segmentés en 6 couches et 6 sections
- Permet de faire du tracking de gamma dans le germanium



L'algorithme de PSA (Pulse Shape Analysis) compare les signaux réels avec une base de données de signaux simulés en utilisant une minimisation par χ^2

Actuellement, caractérisation à l'aide d'une scanning table : Pulse Shape Comparison Scanning method (**PSCS**). On reconstruit les signaux 3D en recoupant les deux plans 2D.

Nouvelle méthode proposée :




Spectroscopie gamma avec AGATA

Présentation de Jérémie Dudouet, IP2I Lyon

2 Long short-term memory (LSTM) layers were used as starting point.

- 4 dense layers are added to obtain a 3D output (X,Y,Z)
- **Masked loss function**: calculated only for the two known axes



The **Neural Network shows better homogeneity** than the PSCS.


Training takes 12 hours, and processing takes 2 hours (vs. 5 days with PSCS)

- The NN showed **better consistency** and **accuracy** than the PSCS method
- Experimental signal bases were generated using both the NN and PSCS, and applied to the PSA
- The **NN-based basis improved the experimental resolution** compared to the default AGATA simulated basis
- A neural network capable of **simulating real signals** was successfully trained
- A neural network was trained on synthetic data to **handle two interactions per segment**
- ➔ This model showed a **28% improvement** over the one-interaction-per-segment network

Discrimination gamma-neutron dans des scintillateurs avec des réseaux de neurones

Présentation d'Olivier Stézowski, IP2I Lyon

- 3 architectures étudiées avec les données de NEDA (détecteur neutrons) : 3 architectures testées (MLP, CNN, LSTM)
- ➤ MLP (perceptron multicouches) a tourné en ligne sur CPU.
- ➤ Les données AGATA ont permis de qualifier la discrimination γ/n dans NEDA
- ➤ LSTM (long short-term memory) a quelques avantages, moins sensible à un désalignement temporel des signaux
- ➤ Auto encoders OK pour compression / de-noising
- Rampe de lancement pour le traitement des signaux AGATA




Auto-encodeur pour
identification des pile-ups

Deep Learning based spectroscopic data generation for spectral identification models

Présentation de Felipe Matheus Fernandes de Oliveira, CEA IRFU

- Projet **CALISTE** : Pixelated detector 16 x 16 pixels pour spectroscopie gamma
- Utilisent un réseau de neurones convolutionnel bayésien entraîné avec des spectres simulés couplé à la réponse du détecteur pour donner la probabilité de présence des radionucléides




En sortie probabilité de présence des radionucléides avec un certain niveau de confiance

Reconstruction par réseaux de neurones pour l'imagerie radio-isotopique

Présentation de Françoise Bouvet, IJC Lab

- Caméra miniature pour l'imagerie gamma




- Test perceptron multicouches avec en entrée 256 valeurs d'énergie et en sortie : 2 valeurs de position (x, y). 1 ou 2 couches cachées ; 10 à 50 neurones / couche.
- Test réseau de convolution avec 1 ou 2 couches de convolution et 4 à 32 filtres /couche.

Reconstruction par réseaux de neurones pour l'imagerie radio-isotopique

Présentation de Françoise Bouvet, IJC Lab

Réseaux de convolution très puissants -> risque de **surapprentissage**

- Apprentissage plus homogène avec les réseaux de convolution vs MLP
- Paramètres les plus influents : **taille du réseau** (nombre de couches, nombre de filtres, nombre de neurones)
- Algorithmes d'optimisation : adamax, adam, rmsprop équivalents
- Difficulté **d'évaluer** les résultats quantitativement
- Importance de la **qualité des données** en apprentissage




Reconstruction par réseaux de neurones pour l'imagerie radio-isotopique

Présentation de Françoise Bouvet, IJC Lab


Autre application :

Deep Residual Convolution architecture

Pour caméra ambulatoire (contrôle de dose temps réel)



Structure d'un bloc convolutif résiduel profond. m est la dimension de l'entrée image, n est la dimension des filtres et k est le nombre de filtres. BN : Batch Normalization.



Levenberg Marquart

Deep Residual Convolution

DeepLearning pour la trajectographie en Physique des Hautes Énergies


Présentation de Corentin Allaire. IJCLab

Présentation du projet **Acts : A Common Tracking Software**




Exemples d'applications :

- Neural Network Calibrator (Louis-Guillaume Gagnon)
- Graph Neural Network GNN4ITk






Sélection des trajectoires et graines



- Trajectographie classique : beaucoup plus de graines et de trajectoires que de particles
 - Utilisation d'un perceptron multicouche pour calculer un **score** par graine/trajectoire
 - DBScan : **Groupe** les trajectoires similaires
 - Garde le **meilleur score par groupe**
-

Inspection visuelle automatique des modules pixel d'Itk avant le wire-bonding

Présentation de Vera Maiboroda, CEA (collab. ATLAS)



Différents algorithmes testés :

- **Unsupervised algorithms** (defects = anomalies)
 - Learn not-anomalous features, distinguish them from anomalous ones with the help of loss function (CFA, PatchCore)
 - Learn to transform not-anomalous features to normal distribution, anomalous features would be transformed into outliers (CFlow, FastFlow)
 - Learn to reconstruct not-anomalous images as not-anomalous via VAE, so that defects are detected based on difference between input and output images (DRAEM)
- **Zero-/few-shot algorithms**
 - Segment-any-anomaly (foundation model)
- **Supervised algorithms**
 - U-net-based (CNN)

L'algorithme finalement retenu est PatchCore entraîné sur les dernières données
best results with tile size 256px, trained on filtered images, with spatial augmentations.
Denoising was dropped due to time-consumption.

Improving the Visual Inspection of new detector components with Anomaly Detection algorithms

Présentation de Louis Vaslin, KEK Japon (Itk pixel modules / ATLAS)

- Two categories of defects

Statistical anomalies


Anomalies that appear in a minority of images
=> **O(1%) occurrence rate**

Very few examples available
=> **Cannot make labeled dataset**

Unsupervised defect detection

Unsupervised defect detection

- Denoising Auto-Encoder
Reconstruct main input fetures and remove defect-like pattern
=> Enhance sensitivity for defect detection
Select pixel areas with **high reco error**
- Clustering and filtering
Apply **clustering** to selected pixels
Keep only major clusters
=> Defect candidates



Expert anomalies


More recurrent/common anomalies
=> **Recognized as defects by experts**

Many examples available
=> **Can make labeled dataset**

Supervised defect classification

Supervised defect classification

- Feature Pyramid Network
Extract high level features from input image
Successive dimension reduction
=> **Pattern of different sizes**
- Classification head network
Use FPN feature space to classify specific defects
=> **Multiple classification objective**




Improving the Visual Inspection of new detector components with Anomaly Detection algorithms


Présentation de Louis Vaslin, KEK Japon

Quelques résultats :

Détection non supervisée des défauts :
Défaut critique détecté avec succès (en rose)



Classification supervisée des défauts :



Application to a flex PCB image

3 defect categories detected

Dust, contamination and scratch

All 3 defects were properly identified

