



PÔLE

MACHINE LEARNING / DEEP LEARNING

du CeSAM (LAM)

**PRÉSENTATION
&
EXEMPLES DE
DEUX PROBLÉMATIQUES**

**Morgan Gray, Simon Conseil, Jean-Charles Lambert,
Jean-Charles Meunier, Christian Surace, Didier Vibert**



Missions du pôle

Personnels du pôle

Infrastructure de calcul intensif (HPC)

École thématique CNRS Astro-Informatique 2021

Anatomie d'un réseau de neurones

2 exemples de problématiques

- Régression :

estimation de paramètres des PSFs en optique adaptative
pour l' E-ELT (**APPLY**) *ou* pour un nano-satellite (**AZIMOV**)

- Classification :

indice de fiabilité des estimations de redshifts spectroscopiques
du pipeline 1D du satellite **EUCLID**

ou classification Etoiles/Galaxies/Quasar à partir des spectres **EUCLID**

MISSIONS du PÔLE ML/DL

Pôle créé en novembre 2020

▶ Apporter une expertise

sur les méthodes de Machine Learning (ML) et de Deep Learning (DL)

pour les *problématiques astrophysiques et instrumentales*,

au sein des *différents projets et équipes* du LAM :

- développement de codes, suivis & conseils,
- ressources personnels (2 ETP en permanents & 2 futurs CDD),
- ressources informatiques (18 GPUs sur le cluster du LAM & aide à l'utilisation des GPUs du Mésocentre Aix-Marseille Université)

▶ Faciliter les interactions

entre les équipes au sein même du LAM,

établir des liens avec les équipes d'autres laboratoires (équipe QARMA du LIS) & des entreprises (start-up SpaceAble...) travaillant sur ces méthodes de ML/DL

▶ Animer des rencontres, transmettre des annonces de formation sur des thématiques relatives au ML/DL

▶ Organisation d'une école thématique CNRS AstroInformatique 2 éditions 2018 & 2021 (prochaine en 2023)

Page du pôle ML/DL : <https://projets.lam.fr/projects/mldl/wiki>

PERSONNELS du PÔLE ML/DL

- Morgan Gray** (100 %) IR, responsable pôle ML / DL
Développement de codes numériques pour les projets APPLY (GRD) ; EUCLID (GECO)
Conseil/support aux projets BigSF (GECO) ; AZIMOV (GRD)
- Simon Conseil** (50 %) IR (*arrivé le 1er fev. 2022*)
Développement de codes numériques pour le projet EUCLID (GECO)
- Jean-Charles Lambert** (5 %) IR, responsable pôle Infrastructure
Développement & Maintenance des GPUs du cluster de calcul du LAM
- Jean-Charles Meunier** (25 %) IR, technologies du BigData
Pré traitement & visualisation de données multisources pour le projet BigSF (A. Zavagno)
- Christian Surace** (5%) IR, responsable du CeSAM
Organisation de l'école thématique CNRS Astro-Informatique (2018 & 2021)
- Didier Vibert** (5 %) IR, responsable pôle TARDIS
Expertise scientifique pour EUCLID (GECO)
- François-Xavier Dupé** (50 %) MdC, détachement (LIS-QARMA)
Développement de codes numériques pour le projet BigSF (GECO)
- Charleston Chauvet** (50 %) CDD-IE 2 ans (*début le 1er juin 2022*)
Collaboration GRD / start-up SpaceAble (plan de relance France 2020-2022)
- Raissa Camelo** (50 %) CDD-IE 2 ans (*début le 1er sept. 2022*)
Collaboration GRD / start-up SpaceAble (plan de relance France 2020-2022)

INFRASTRUCTURE DE CALCUL INTENSIF

Matériel

Système linux Almalinux 8


Gestionnaire de jobs **SLURM**

Total de **42** noeuds de calcul (**1120** cpus)

→ calcul **CPU** : **2.5 M** heures (année 2021)

6 noeuds dédiés au **Machine Learning / Deep Learning** (**18** cartes GPU)

→ calcul **GPU** : **75 K** heures (année 2021)



Partitions de calcul slurm : **batch** : jobs séquentiels + parallèles partagés / OpenMP

mpi : jobs parallèles distribués / MPI

mem : jobs interactifs + jobs mémoire

gpu : jobs ML/DL & cuda

Stockage

Systeme TrueNAS

480 TB d'espace partagés NFS



Réseau d'interconnexion

1 Gigabit/s ethernet entre les noeuds

100 GB/s réseau faible latence infiniband

pour le calcul parallèle MPI

INFRASTRUCTURE DE CALCUL INTENSIF

Logiciel

Compilateurs GNU et Intel
Bibliothèques scientifiques

Environnement conda
Python



Jupyter notebook
Travaux python interactifs sur le cluster



Matlab compiler runtime
Execution de jobs MATLAB sur le cluster



IDL

Environment pour le Machine Learning /Deep Learning

CUDA 11.5
Tensorflow
Pytorch



ÉCOLE THÉMATIQUE CNRS ASTROINFORMATIQUE 2021

Objectifs

- ▶ **Former des membres** de la communauté INSU Astrophysique aux méthodes d'analyse des grandes masses de données avec les outils les plus récents
- ▶ **Faire intervenir** des formateurs reconnus pour leurs expertises en ML/DL
- ▶ **Définir** des projets et **établir** des liens plus forts entre les communautés informatique et astrophysique afin d'assurer une meilleure cohésion interdisciplinaire
- ▶ **Réaliser** un projet concret au travers d'un **Hackathon**

Instituts scientifiques : **INSU / IN2P3 / INS2I**

Nb de participants : 35 (dont 23 CNRS)

Déroulement

- ▶ **Semaine 1** : Alternance de **cours, TP & discussions informelles**
Classification Supervisée / Non supervisée Pré traitement des données
Réseaux de neurones (bases, réseaux convolutifs, récurrents, probabilistes...)
- ▶ **Semaine 2** : - Hackathon sur 2 sujets différents (petits groupes et encadrés par des experts)
- Recherche & expérimentation, utilisation du super ordinateur du CNRS Jean Zay
- Séances d'approfondissement de certaines notions en DL, publication en préparation

Bilan très positif : introduction graduelle des notions, interactions & collaborations efficaces

Prochaine session : juin 2023

Page de l'École Thématique : <https://astroinfo2021.sciencesconf.org/program>

ANATOMIE D'UN RÉSEAU DE NEURONES

Couche (dense / de convolution) Tenseur → Tenseur

neurones, poids, # filtres, kernels, strides, padding, fonctions d'activation, initialiseurs...

Fonction de Perte avec Labels "Prédits" & Labels "Vrais"

calcul d'une Distance / Mesure de perte

Optimizer Algorithme de rétropropagation du gradient des erreurs

permet de déterminer les valeurs des paramètres du réseau minimisant la Fonction de Perte

Métrique évaluation de l'évolution des performances

Modèle architecture du réseau de neurones & choix des différents paramétrages

ENTRAÎNER le modèle d'un réseau de neurones

Répéter un "nombre suffisant" de fois (# d'époques)



la boucle d'apprentissage,

- en propageant des batchs (petites parties)


d'un ensemble d'apprentissage (Training Set)

- en minimisant la fonction perte,

⇒ détermination les valeurs des paramètres du réseau



Couches Denses



Couche de Convolution

APPLY : PROBLÉMATIQUE DE RÉGRESSION

But

- Caractériser conjointement la turbulence atmosphérique et les aberrations optiques du télescope à partir de la PSF (Point Spread Function) résultante,
- Réduire la dimensionnalité de la description des phénomènes physiques en utilisant un modèle avec seulement 15 paramètres.

Model of the wavefront spatial PSD


$$W(k \leq k_{AO}) = M(k, A, \alpha, \rho, \beta) + C$$

$$W(k > k_{AO}) = 0.023 r_0^{-5/3} k^{-11/3}$$




$$PSF_{atm} = F^{-1}[\exp(F[W])]$$

Atmospheric component (maoppy)




TASK 2:



Méthode

- Apprentissage d'un réseau de neurones CNN sur des simulations de PSFs correspondant à 2 instruments : NIRC2 / Keck (10m) ; IRDIS / VLT (8m)
- Comparer les performances avec les méthodes d'estimations classiques de psf-fitting




PSFAO21 model : 6 to 15 parameters

$$PSF(\mu_{stat}, r_0, C, A, \alpha, \rho, \beta) = PSF_{stat}(\mu_{stat}) * PSF_{atm}(r_0, C, A, \alpha, \rho, \beta)$$



APPLY : PROBLÉMATIQUE DE RÉGRESSION

Résultats - PSF non bruitées :

Résidu de turbulence au % près,
Alignement des segments au nm près
Performances du réseau de neurones **supérieures** aux méthodes classiques d'ajustement de modèles (pb de couplage entre les paramètres atmosphériques et ceux du télescope)




- PSF bruitées : **Amélioration d'un facteur 2** par rapport aux méthodes d'ajustement de modèles



Autre Exemple

Projet AZIMOV


Estimation de la PSF (12 modes de Zernike) pour le cophasage des 4 pétales du miroir d'un nanosatellite d'observation de la terre



EUCLID : PROBLÉMATIQUE DE CLASSIFICATION

But

- Classer suivant un **indice de fiabilité** les estimations de redshifts spectroscopiques à *partir des LogPDF* fournies par le pipeline 1D Amazed du satellite EUCLID (étude de l'énergie noire),
- **Automatiser la classification** pour un **traitement sur toute la "chaîne de calcul"** d'1 spectre/minute



- Proposer différents types de classifieurs suivant différents critères de classification.


<https://euclid-france.fr/contexte-et-objectifs/>

EUCLID : PROBLÉMATIQUE DE CLASSIFICATION


- Méthode**
- Apprentissage d'un **réseau de neurones CNN-1D** sur des simulations et données réelles
 - Comparaison les performances avec la "redshift probability" fournie par le pipeline Amazed

- Résultats**
- Utilisation des **courbes de Purity (Precision) / Completeness (Recall)** définies avec la classe "success" (plusieurs définitions possibles : classiques, adaptées aux spécificités EUCLID)
 - l'objectif est de déterminer des seuils pour atteindre : **Purity > 0.8 & Completeness > 0.45**

Critère avec 2 classes



Critère avec 3 classes



Autre Exemple

Projet **EUCLID** : classification Etoiles / Quasars / Galaxies à partir des spectres
Travail de Simon Conseil (démarré récemment, phase exploratoire)

CeSAM

Pôle Machine Learning / Deep Learning

(responsable : morgan.gray@lam.fr)

<https://projets.lam.fr/projects/ml/dl/wiki>

Pôle Infrastructure HPC

(responsable : jean-charles.lambert@lam.fr)

<https://projets.lam.fr/projects/cluster-de-calcul-du-lam/wiki#Presentation>