CoDPy est un framework alternatif aux plateformes traditionnelles de ML

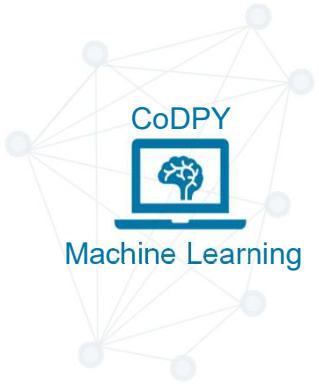

Librairie de ML sous python / C++, open-source

Basée sur la théorie des noyaux reproduisants

Disposant d'une documentation solide écrite sous RMarkdown (~jupyter notebook)

Prédiction

Créer des modèles de prédiction performant en précision et temps de calcul

Boîte blanche

Expliquer chaque étape de la modélisation et créer une mesure d'erreur ex-ante sur chaque modèle

Segmentation

Segmenter des ensembles de données homogènes avec précision et stabilité

Analytics

Utiliser des fonctionnalités facilitant la traduction de problématiques d'ingénierie financière

MPG PARTNERS

CoDPy est une technologie mature qui a déjà fait ses preuves

20 publications

qui portent sur les fondements mathématiques de CoDePy et les algorithmes (Kernel Methods)

3 revues Alpha

WILMOTT MAGAZINE

COMPTE RENDU POUR L'ACADEMIE DES SCIENCES

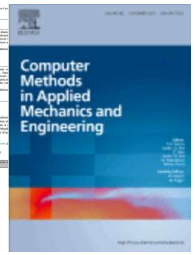

COMPUTER METHODS IN APPLIED MECHANICS AND ENGINEERING

5 partenaires clés

Entreprise membre de bpifrance EXCELLENCE 2018

cnrs

Finance Innovation
Projet labellisé

QuantUniversity, LLC

TSE
Toulouse School of Economics
École d'économie de Toulouse

8 années de R&D

Financées par MPG Partners et en étroite collaboration avec le Laboratoire Jacques Louis Lions du CNRS

6 use cases réalisés

- Couverture de bilan bancaire
- Optimisation du recouvrement
- Pricing de portefeuilles d'Autocall
- Reverse Stress Tests
- Pricing de prix futurs d'une option
- Fraudes de cartes bleus

3 use cases clients

GROUPE BPCE
Coopératifs, banquiers et assureurs autrement.

CAISSE D'EPARGNE

SOCIETE GENERALE

MPG PARTNERS

CoDPy permet de faire des prédictions simplement avec d'excellentes performances

Prédiction

Performance : Cette technologie permet de construire des machines d'apprentissages qui surperforment systématiquement les grandes plateformes d'Intelligence Artificielle en terme de précision

Explicabilité: Le score obtenu peut être anticipé (par la mesure d'erreur, cf slide 14) et nos prédictions sont parfaitement explicables et auditables

Nature des données : La librairie CoDPY est particulièrement adaptée à des données parcimonieuses ;

Benchmark avec **Google Tensorflow** sur le test MNIST (KAGGLE)

Illustration 1 : Benchmark performance de prédiction entre CoDPY (projection et extrapolation) versus Google Tensorflow

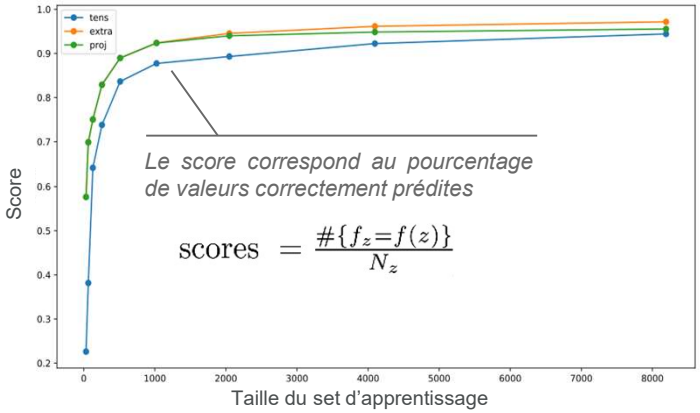

- **Google Tensorflow** (paramétrage standard)
- **CoDPY Extrapolation** : (paramétrage standard)
  Utilise toutes les données du set d'apprentissage. Précise mais coûteuse en temps de calcul.
- **CoDPY Projection** : (paramétrage standard)
  Utilise un sous ensemble du set d'apprentissage. Moins précise, mais très bonnes performances.

Simplicité du paramétrage sous CoDPY

```
codpy_param = {'set_kernel': 'gaussian'}
```

Complexité du paramétrage sous Tensorflow

```
import tensorflow as tf
tf_param = {'epochs': 10,
'batch_size':16,
'validation_split':0.1,
'loss': tf.keras.losses.SparseCategoricalCrossentropy(from_logits=True),
'optimizer':tf.keras.optimizers.Adam(0.001),
'activation':['relu',''],
'layers':[128,10],
'metrics':[tf.keras.metrics.SparseCategoricalAccuracy()]}
```

MPG PARTNERS

CoDPy permet de créer des modèles auditables parce qu'associés à une mesure d'erreur

Boîte blanche

- **Explicabilité :** cette mesure, quand calculée sur un set d'apprentissage et de test, permettent d'expliquer les résultats. **Essentiel ! Une méthode de cross validation ne suffit pas.**
- **Implémenté / testé sous python :** cette mesure est largement utilisée au sein de la librairie.

Notre approche de l'estimation d'erreur passe par la fonction de **mesure de discrépance** suivante, nous permettant d'évaluer **la worst error (une erreur ex-ante)** :

$$\| f(z) - f_z \| \leq d_k(x, y, z) \| f \|_{H_k}$$

Les écarts entre la fonction exacte et la fonction prédite sont bornés …

… par la fonction de discrépance d_k ,calculée sur les paramètres x, y et z qui représentent les différentes données utilisées (entrainement, weighted, tests) …

… et la norme de la fonction dans un espace de Hilbert

MPG PARTNERS

CoDPy permet de reproduire les set d'apprentissage

Boîte blanche

Reproductibilité : l'erreur de prédiction est nulle quand l'ensemble de test est le même que l'ensemble d'apprentissage.

Explicabilité : la notion de reproductibilité permet d'interpréter et d'expliquer les résultats d'une prédiction comme une combinaison linéaire du set d'apprentissage.

Benchmark avec les algorithmes **Decision Tree**, réseau de neurones de **Pytorch**, réseau de neurones **Google Tensorflow** sur le test Boston Housing Price (KAGGLE)

Le protocole de test consiste en une série de dix tests :

- L'apprentissage des modèles se fait par séquence croissante de 56 prix à 506 prix de maisons.
- La prédiction est faite sur le prix de l'ensemble des maisons (donc une partie de l'ensemble de test est comprise dans l'ensemble d'apprentissage).
- Reproductibilité : l'erreur sur le dernier point doit être nulle

Illustration 1 : Benchmark des scores de prédiction - Boston Housing Price

Database: *Boston Housing Prices (506 maisons – 13 caractéristiques)*
Indicateurs de performance: *RMSE %.*

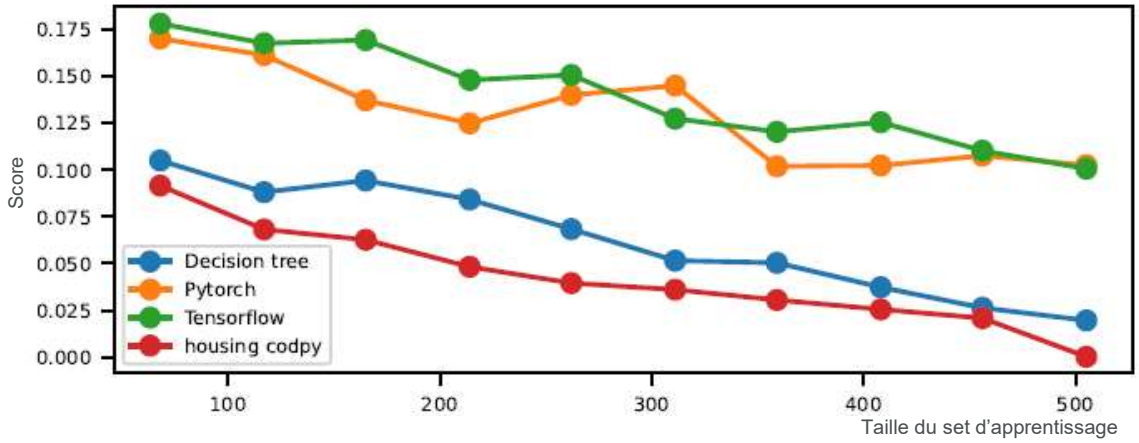

MPG PARTNERS

CoDPy permet de faire de la segmentation de manière robuste

Segmentation

Innovation : les suites à faible discrépance sont un nouvel algorithme performant pour faire de la segmentation

Stabilité : cet algorithme est stable, la segmentation est déterministe et convergente

Benchmark avec l'algorithme **Kmeans de scikit-learn** sur un cas de fraude de cartes bleues (KAGGLE)

Illustration 1 : Benchmark de la stabilité et des scores de prédiction

Database: *Kaggle credit card fraud detection (284 000 lignes – 500 fraudes)*
Indicateurs de performance: *taux de détection / erreur de discrépance.*
N = nombre de clusters

CoDPY est plus stable que KMeans

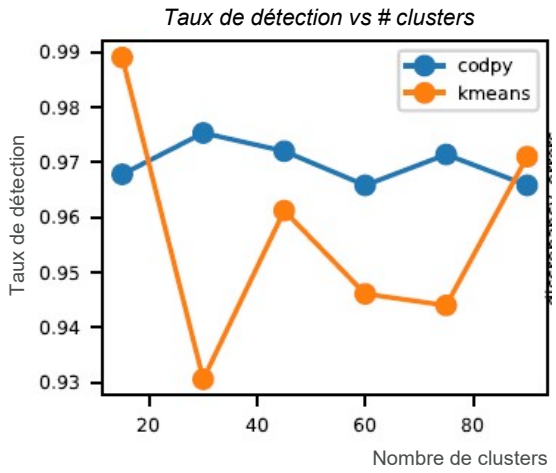

Nx

CoDPY est plus performant que KMeans

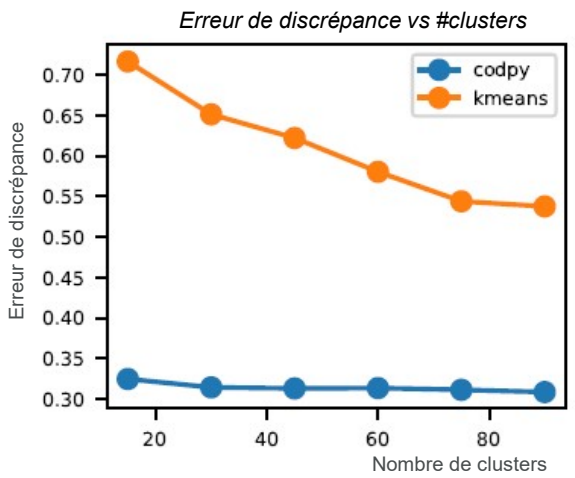

Nx

MPG PARTNERS

CoDPy permet d'accéder à des outils de simulations numériques pour le calcul de risques

Analytics

Opérateurs différentiels : Accès à tout opérateur différentiel (e.g. sensibilités / gammas et plus encore). Permet de résoudre une grande variété de problèmes décrits par les équations aux dérivées partielles.

Le calcul de sensibilité est très efficace: performant, robuste et non intrusif**, meilleures performances que l'AAD**, pas de librairie tierce à installer.

Transport optimal: Accès à des fonctionnalités de transport optimal. Pour le management des risques, seul ces outils permettent de calculer raisonnablement des **matrices de transitions de probabilité**, ou **générer des séries temporelles fiables** (Focus slide 18)

	Exemples de problématiques	Fonctionnalités CoDPY	Avantages
Diffusion de sous-Jacents	- **Réplication de séries temporelles** (historique) Calibration des modèles paramétriques - Modèles de diffusion stochastique (risque neutre): adéquation observations / modèles - Performance et précision au regard de la multitude de sources de risques	- Problème inverse : fonction de projection - Fonction de sampling z=S(x,N) - Calcul de suite de faibles discrépance pour les processus stochastiques	- Méthode généraliste - Méthode agnostique : pas d'hypothèse sur la distribution initiale - Simulation de trajectoires Monte-Carlo à partir de données historiques - Convergence rapide des résultats
Valorisation	- Rétropropagation - Calcul de **probabilités conditionnelles** (CVA / risque de crédit) : Multitude de pricer / modèles - Calculs d'erreurs / intervalle de confiance	- Calcul complet de la nappe des prix futurs - Fonction fz|x = Pi(x,z,f(z))	- Calcul très efficace (pas de Monte-Carlo de Monte-Carlo) - Calcul de matrice de probabilité de transition - Estimation d'erreurs
Métriques de risques	- Calcul de sensibilités / dérivées - Evaluation de scenario	- **Fonction de dérivation** : Nabla, Hessian, Divergence, autres	- Calcul de sensibilité très rapide
Stratégies de couverture	- Evaluation de stratégies - Backtesting de stratégies	- Optimisation sous contraintes	- Evaluation de stratégies complexes (type américain / bermudéen ou hedging complexe)

MPG PARTNERS

Focus sur la fonction de réplication de séries temporelles (sampling)

Analytics

- **Algorithmes de factorisation polaire :** cette collection d'outils provenant du transport optimal nous donne accès à des algorithmes inédits en Machine Learning, tel que la factorisation polaire. La fonction de sampling que nous proposons est une application directe de cette factorisation ;

- **Fonction de sampling :** un outil nous permettant de re-sampler n'importe quelle distribution. Très pratique pour générer des données de test ! Sa fonction est de générer des échantillons partageant les mêmes propriétés statistiques que la distribution originale. Essentiel pour la **simulation de trajectoires Monte-Carlo** à partir de données historiques (séries temporelles).

Notre fonction de sampling :

En entrée (inputs)

- des échantillons iid d'une variable aléatoire

En sortie (output) : ,
une distribution partageant des propriétés statistiques proches de x

Illustration (en 3D sur deux axes) d'une distribution multidimensionnelle bimodale, avec la distribution originale (en bleu) versus la distribution généré (en rouge)

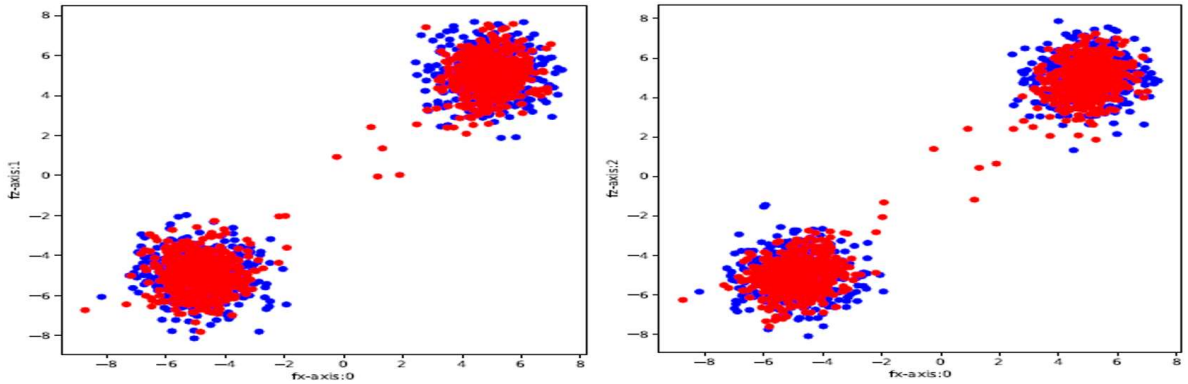

MPG PARTNERS

Nos publications scientifiques se découpent en deux volets : une **partie théorique** qui porte sur les fondements mathématiques de nos méthodes innovantes et une **partie algorithmique** qui porte sur notre librairie d'algorithmes (Kernel Methods) :

Théorie

- *"A class of mesh-free algorithms for mathematical finance, machine learning and fluid dynamics* – Ce papier est l'essence même de notre approche ;
- *"The Transport-based Mesh-free Method (TMM) and its applications in finance: a review*" – publié dans Wilmott magazine, Ce papier est une presentation générale de notre approche ;
- *"Mesh-free error integration in arbitrary dimensions: A numerical study of discrepancy functions*" – publié dans Computer Methods in Applied Mechanics and Engineering. Ce papier se concentre sur l'erreur d'analyse pour la méthode Reproducing Kernel Hilbert Space (RKHS) ;
- *"A new method for solving Kolmogorov equations in mathematical finance"* - Comptes Rendus Mathématique, Volume 355, 6ème édition, Juin 2017, Pages 680-686. Ce papier explique la stratégie des équations différentielles partielles pour les mathématiques financières et propose un certain nombre d'exemples numériques ;
- *"Revisiting the method of characteristics via a convex Hull algorithm"* – publié dans le Journal of Computational Physics, Octobre 2015 (lien référence) Ce papier traite de l'application de cette méthode pour les lois de conservation ;
- *"A high dimensional framework for financial instruments valuation*" – publié en 2013 ce papier est un premier essai pour décrire notre approche et la résolution d'équations aux dérivées partielles multidimensionnelle en mathématiques financières ;
- *"Optimally transported schemes"* – Papier portant sur le traitement pour le cas à une seule dimension ;

Algorithmes

- *"CoDPY -Tutorial"* – une première introduction de notre librairie, notamment sur le focus du Machine Learning ;
- *"CoDPY - Advanced Tutorial"* – une description technique de notre librairie CoDPY ;
- *"A kernel based reordering algorithm"* – description de l'algorithme central de reorganization de notre approche ;
- *"A kernel based polar factorization and the sampling algorithm with CoDPY"* –description de notre algorithme de calcul de factorisation polaire. Cet algorithme est illustré à travers un outil très pratique permettant de produire des échantillons IDD à partir de n'importe quelles distributions d'inputs ;
- *"A kernel-based algorithm to compute conditional expectations"* –un algorithms important pour les applications en Finance. Nous avons benchmarké l'implémentation de cet algorithme, en comparant notre framework à une approche Classique de Neural Network ;
- *"Hedging Strategies for Net Interest Income and Economic Values of Equity"* – une description d'un prototype utilisant CoDPY, ayant pour but la construction de stratégies sophistiquées sur des sujets d'ALM ;
- *"Kernel methods for stress test and reverse stress test"* – description de notre approche Support Vector Machine avancée aux Stress Tests et Reverse Stress Tests ;