

Sujets TP d'application

INT21 — 2025

Par groupe de 2 ou 3 personnes

TP simples :

- Faire un algo mémétique et le comparer à l'algo simple, tester sur des Weierstrass et sur Rastrigin.
- Programmer un niching et tester sur Rastrigin en grande dimension.
- Comparer différents algorithmes d'optimisation multi-objectifs.
- Programmer un algorithme multi-population (modèle en îlots), le comparer à un algo classique.

TP de difficulté moyenne :

- Programmer et tester différentes mesures de diversité.
- Régression symbolique : A Living Benchmark for Symbolic Regression
- Régression symbolique pour prédire les émissions d'ammoniaque dans l'environnement
- Labyrinthe avec ArenaBot.
- Optimisation d'un réseau de neurones.

TP plus compliqués :

- Visualisation des trajectoires d'apprentissage en GP dans un espace sémantique.
- Co-evolution coopérative : problème « Lamps ».
- Co-évolution compétitive : modèle prédateur/proie.
- Exploring Hawk-Dove games
- Evolution interactive d'ensembles de Julia.

Sujet « sur mesure » sur demande

Contrôle

- **Présentation 10 min + 5 min questions**
- **Présenter méthode, résultats**
- **Analyse critique !**

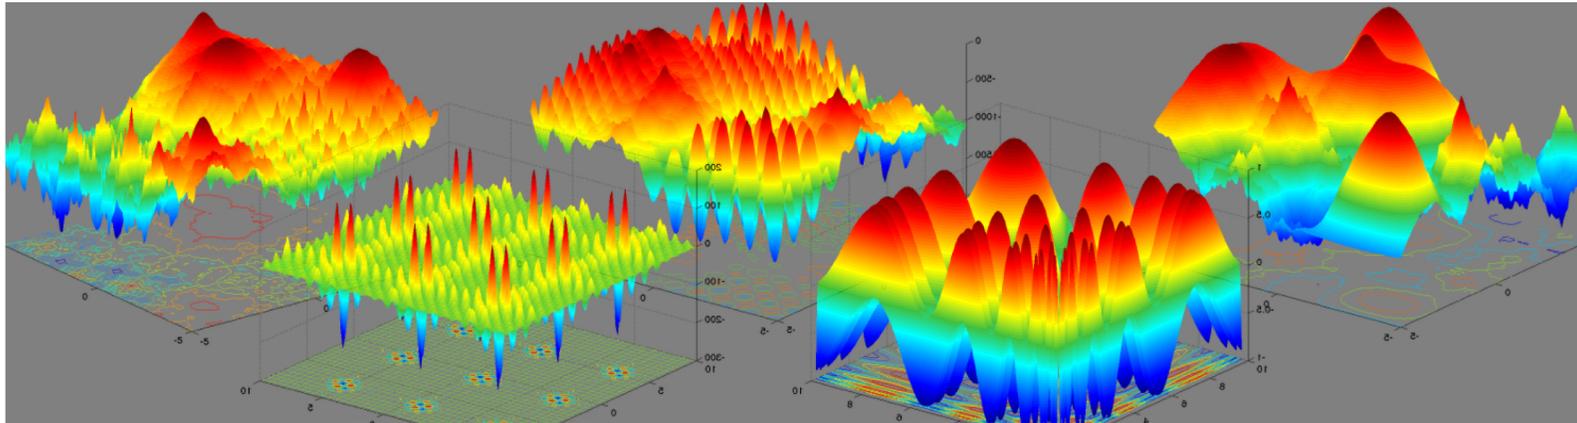
Algorithme évolutionnaire mémétique

- **Optimisation évolutionnaire classique, mais dotée de capacités “d’apprentissage”. En général : rajout d’une optimisation locale lors de l’évaluation de chaque individu.**
- **Implémentation avec inspyred.**
- **Tester `scipy.optimize.minimize` comme optimiseur local.**
- **Paramétrage et comparaison de l’approche mémétique avec l’approche classique.**



Niching : Identification des différents optima

- Fonctions multi-modales :

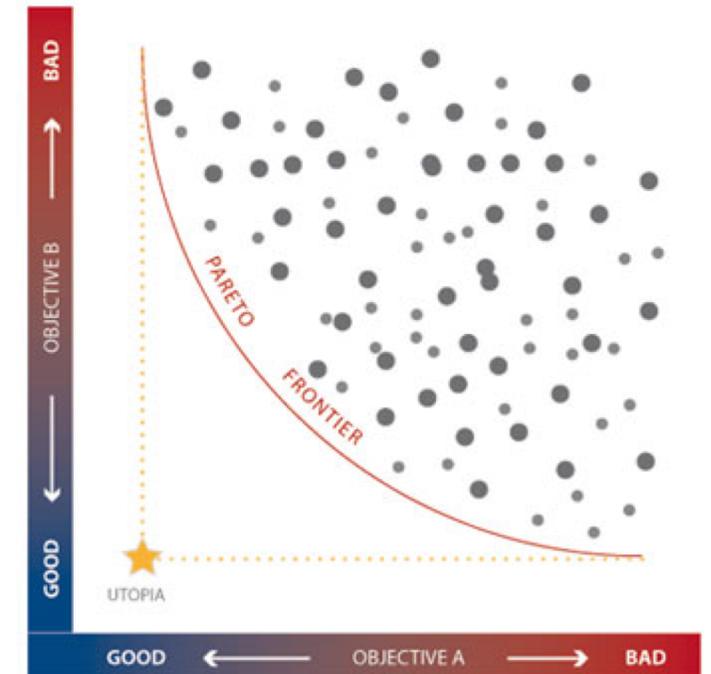


- L'optimisation évolutionnaire classique converge vers un seul optimum local.
- Solution : Forcer la population à converger vers plusieurs optima plutôt qu'un seul.
- Implémenter à l'aide d'inspyred une ou plusieurs méthodes de niching.
- Tester les méthodes sur des fonctions multi-modales et comparer leurs performances avec l'optimisation évolutionnaire classique (code TP1).



Comparaison de différents algorithmes d'optimisation multi-objectifs

- Comparer les performances entre NSGA-II, NSGA-III et MOEA/D
 - Temps de calcul,
 - Qualité des fronts obtenus (programmer différentes métriques).
- Utilisation de différents problèmes multi-objectifs, avec un nombre d'objectifs variable.
- Lien code : <https://pymoo.org>
- Benchmarks : <https://pymoo.org/problems/multi/zdt.html>



Niveau de difficulté ★

Algorithme multi-populations : modèle à îlots

- Point de départ : <https://pythonhosted.org/inspyred/examples.html#island-models>
- Comparer avec un modèle mono-population utilisant le même nombre d'évaluations.
- Faire varier le nombre d'îlots, les fréquences de communication.
- Sur différentes fonctions-test (Rastrigin, Weierstrass).

Mesurer et suivre la diversité

- Programmer une mesure de diversité de population.
 - Mesures **géométriques** : somme, max, moyenne des **distances** entre toutes les paires possibles d'individus (définir une distance sur l'espace de recherche : **phénotypique**, **génotypique**, **fitness** ?)
 - Mesures **statistiques** (variance, écart-type, caractéristiques calculées sur les histogrammes des valeurs de gènes, entropie de Shannon)
- Affichage à chaque génération (petite visualisation).
- Tester et comparer les mesures de diversité (différents paramétrages d'AE sur quelques fonctions-test).

<https://aarongarrett.github.io/inspyred/reference.html#benchmarks-benchmark-optimization-functions>



Régression symbolique : A Living Benchmark for Symbolic Regression

Utiliser le code <https://cavalab.org/srbench/> pour tester PySR, Gplearn et PyOperon (accessibles par pip install) sur :

- <https://github.com/cavalab/srbench>
- <https://cavalab.org/srbench/user-guide/#reproducing-the-experiment>
- <https://github.com/heal-research/pyoperon>

Régression symbolique pour prédire les émissions d'ammoniaque dans l'environnement

- **Jeu de données : tableau excel d'émissions d'ammoniaque (NH₃) dans l'environnement en fonction d'autres paramètres (température, vent, fertilisant, ... et du temps)**

$$\frac{dy}{dt} = f(y, x_1, x_2, \dots, x_n)$$

- **Transformer les données du tableau pour apprendre la fonction f par programmation génétique.**
- Utiliser PySR ou GPLEarn ou autre



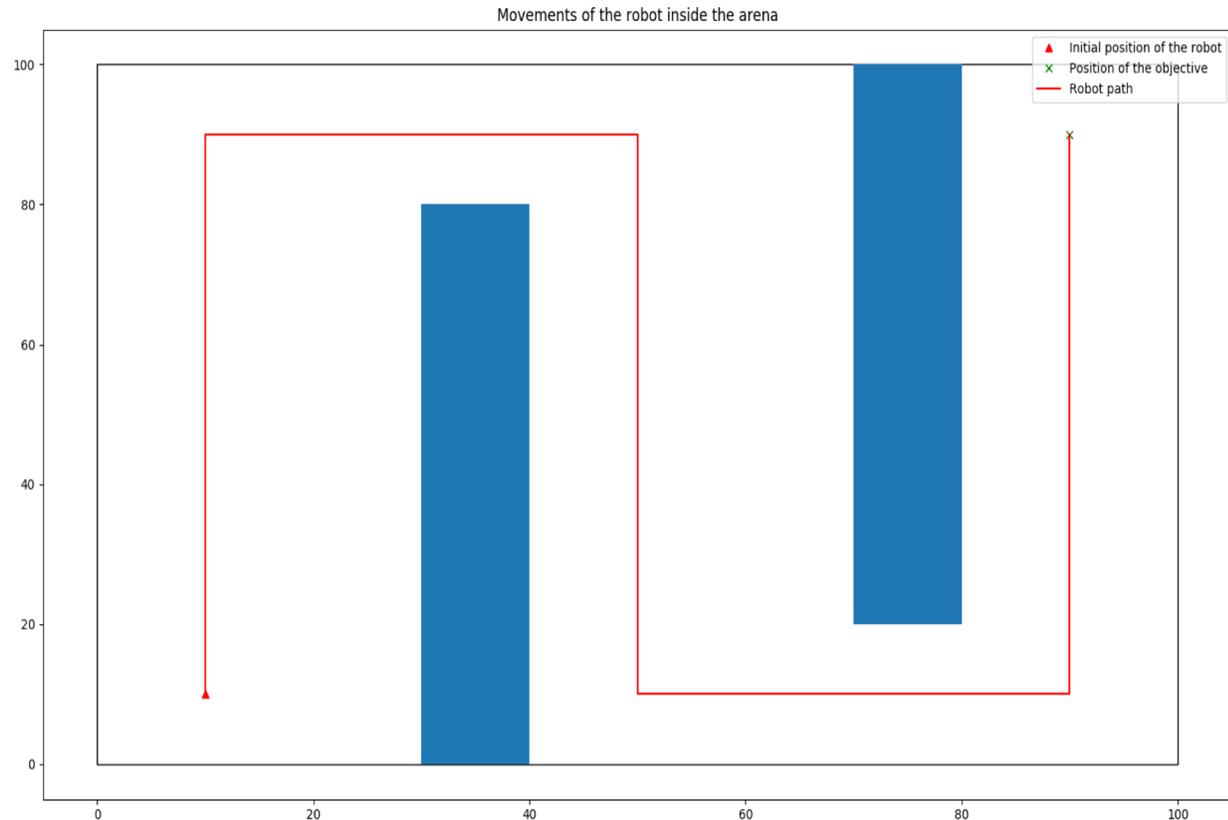
« L'ammoniaque est un facteur déterminant dans la production de particules fines »

Armand Favrot,
Doctorant INRAE, MIA-PS



Labyrinthe

- A l'aide d'inspyred, écrire un algo GP pour aider un "robot" à trouver son chemin dans un labyrinthe
- Le robot va recevoir une liste de commandes ("move 80", "rotate 90", "move 20", ...) et la fitness évalue la distance de l'objectif.
 - Le robot ne peut pas passer à travers les murs.
 - La fonction dans **arenabot.py** calcule la fitness pour une liste de commandes donnée.



Optimisation de réseaux de neurones

- **Prérequis : une bonne connaissance en apprentissage de réseaux de neurones artificiel (Keras ou PYTorch)**
- **Jeu de donnée : OpenML.org**
- **Apprendre les poids et la structure d'un réseau de neurones par optimisation évolutionnaire.**
- **Réduire au maximum la complexité du réseau tout en gardant un niveau de prédiction satisfaisant (multi-objectifs ?).**

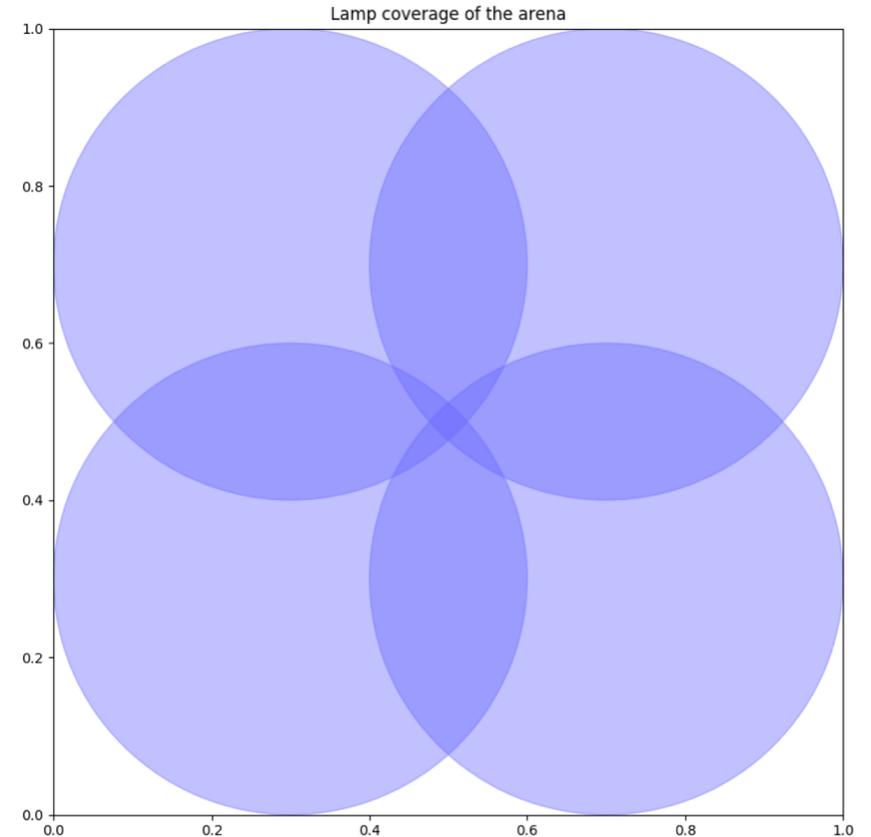


Visualisation des trajectoires d'apprentissage en GP dans un espace sémantique

- Visualiser le comportement d'un algorithme de PG sur un problème de régression (au choix)
- Calculer la position du meilleur individu au cours des générations dans un espace sémantique de grande dimension (voir cours GP).
- Faire une réduction dimensionnelle pour une visualisation en 2D.
voir code sur <https://github.com/albertotonda/experiments-cosine-similarity>)
- Tester, comparer, plusieurs algorithmes : PySR, PyOperon, GPLearn.

Co-evolution coopérative

- Avec un cas d'étude "lamps", utiliser inspyred (ou autre) pour créer un "cooperative co-evolutionary algorithm"
- Chaque individu est un lampe (un cercle), et l'objectif global c'est de couvrir le carré avec le minimum de lampes. La fitness de chaque lampe est son recouvrement du carré.



Co-évolution compétitive : prédateur/proie

- Point de départ = modèle à base d'agents wolf/sheep :
https://github.com/projectmesa/mesa/tree/main/mesa/examples/advanced/wolf_sheep
- Deux populations : les loups et les moutons.
- Génomes = caractéristiques individuelles des agents (loups ou moutons).
- Evaluation = chaque individu a un niveau d'énergie qui correspond à sa fitness.
- Sélection / Croisement / mutation évolutionnaire pour chaque population (à programmer !).

Exploring Hawk-Dove games

<https://www.nature.com/articles/s41598-017-04284-6#:~:text=While%20hawks%20are%20willing%20to,c%20H%20%2C%20while%20doves%20retreat.>

Article | [Open access](#) | Published: 06 July 2017

Evolutionary dynamics of N-person Hawk-Dove games

[Wei Chen](#), [Carlos Gracia-Lázaro](#), [Zhiwu Li](#) , [Long Wang](#) & [Yamir Moreno](#)

[Scientific Reports](#) **7**, Article number: 4800 (2017) | [Cite this article](#)

7715 Accesses | **20** Citations | **22** Altmetric | [Metrics](#)

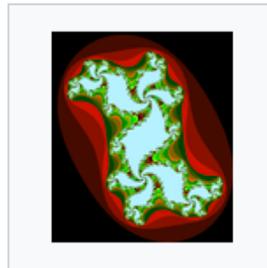
Niveau de difficulté



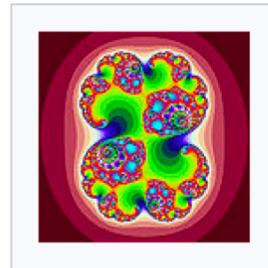
Exploration interactive d'images fractales : ensembles de Julia.

- **Ensembles de Julia :**

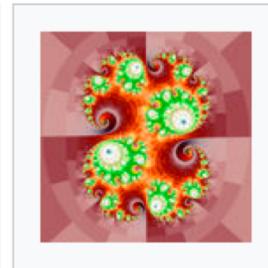
Comportement de la suite $z_{n+1} = z_n^2 + c$ dans le plan complexe.



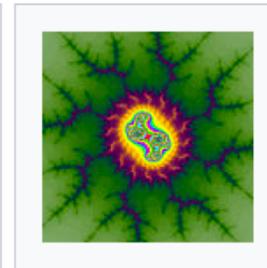
Ensemble de Julia de $z^2 + c$ avec $c = 0.3 + 0.5i$.



Ensemble de Julia pour $c = 0.285 + 0.01i$ (courbes de niveau du nombre d'itérations).



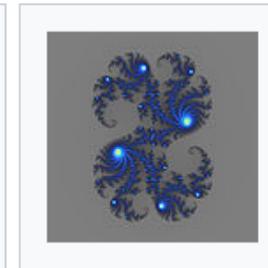
Le même ensemble avec une coloration différente (nombre d'itérations et [pavage](#) selon le secteur d'arrivée).



Détail de l'ensemble de Julia pour $c = -1.417022285618$.



Détail de l'ensemble de Julia pour $c = -0.038088 + 0.975$.



Ensemble de Julia pour $c = 0.285 + 0.013i$.

- **Génome : $c = x + iy$ + table de couleurs + ?**
- **Evaluation interactive par un slider.**
- **Présentation d'une population, vote et itération suivante.**