



HAL
open science

Découverte de nouveaux algorithmes de recherche locale par neuro-évolution

Quentin Suire, Olivier Goudet, Adrien Goëffon, Sylvain Lamprier, Frédéric Saubion

► To cite this version:

Quentin Suire, Olivier Goudet, Adrien Goëffon, Sylvain Lamprier, Frédéric Saubion. Découverte de nouveaux algorithmes de recherche locale par neuro-évolution. ROADEF 2025, Société Française de Recherche Opérationnelle et d'Aide à la Décision (ROADEF), Feb 2025, Champs-sur-Marne, France. ⟨hal-05288561⟩

HAL Id: hal-05288561

<https://hal.science/hal-05288561v1>

Submitted on 29 Sep 2025

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire HAL, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



HAL Authorization

Découverte de nouveaux algorithmes de recherche locale par neuro-évolution

Quentin Suire, Olivier Goudet, Adrien Goëffon,
Sylvain Lamprier et Frédéric Saubion

LERIA, Université d'Angers - 2 Boulevard Lavoisier, Angers, 49045, France

{quentin.suire,olivier.goudet,adrien.goëffon,sylvain.lamprier,frederic.saubion}@univ-angers.fr

Mots-clés : *Neuro-évolution, Recherche locale, Optimisation boîte noire, Modèle NK*

1 Introduction

Dans ce travail, nous nous intéressons aux problèmes d'optimisation combinatoire pseudo-bouéliens pour lesquels l'espace de recherche est défini par $\mathcal{X} = \{0, 1\}^N$. La qualité des solutions est alors évaluée par une fonction objectif $f_{\text{obj}} : \mathcal{X} \rightarrow \mathbb{R}$, dont nous considérons qu'elle n'est pas explicitement décrite (optimisation « boîte noire »).

Les algorithmes de recherche locale [3] explorent \mathcal{X} en sélectionnant successivement des éléments $x_t \in \mathcal{X}$, $t \in \llbracket 0, T \rrbracket$ liés entre eux par une relation de voisinage $V \subset \mathcal{X} \times \mathcal{X}$, de telle sorte que $(x_t, x_{t+1}) \in V$. La manière de choisir le voisin x_{t+1} d'une solution courante x_t est guidée par des stratégies qui exploitent les observations courantes (e.g., choisir un voisin améliorant) et éventuellement celles accumulées au cours de la recherche (e.g., ne pas re-sélectionner un voisin déjà rencontré). Leur efficacité repose sur la capacité à visiter des solutions de haute qualité et dépend fortement des caractéristiques des instances. Dans notre contexte, la relation de voisinage est induite par une opération d'inversion de bit $\text{flip}_i : \mathcal{X} \rightarrow \mathcal{X}$, où $i \in \llbracket 1, N \rrbracket$ qui permet de considérer comme voisins toutes les solutions à une distance de Hamming de 1.

Nous proposons alors d'abstraire un tel processus de recherche locale par un réseau de neurones artificiels. Cette approche permet de découvrir des stratégies performantes, mieux adaptées à différentes distributions d'instances rencontrées.

2 Conception d'algorithmes de recherche locale pour la résolution de problèmes pseudo-bouéliens

Dans la continuité de [1], nous introduisons une politique de recherche locale déterministe $\pi_\theta : \Omega \rightarrow \mathcal{A}$, appelée *Neuro-LS*. Cette politique est basée sur un réseau de neurones g_θ , paramétré par un vecteur $\theta \in \mathbb{R}^d$.

Utilisant à présent le vocabulaire de l'apprentissage par renforcement, étant donné un état $x \in \mathcal{X}$, le réseau de neurones reçoit en entrée une matrice d'observations $o(x) \in \Omega$ (où Ω est l'espace des observations) et produit un vecteur $g_\theta(o(x))$ de dimension N . Chaque composante $g_\theta(o(x))_i$ représente un score de préférence associé à l'observation $o(x)_i$. L'action a_i correspondant au score maximal $g_\theta(o(x))_i$ est alors sélectionnée : $a_i = \arg \max_i g_\theta(o(x))_i$.

Nous considérons cette tâche comme un problème d'optimisation boîte noire continu, θ est optimisé via un algorithme adéquat (dans notre cas CMAS-ES [2]).

Pour une instance donnée $I = (\mathcal{X}, f_{\text{obj}})$, une solution initiale $x_0 \in \mathcal{X}$ (état initial), une politique π_θ , et un horizon H , alors une trajectoire $T(\pi_\theta, I, x_0, H)$ est définie comme une séquence d'états et d'actions $(x_0, a_0, x_1, a_1, \dots, x_{H-1}, a_{H-1}, x_H)$ telle que $\forall i \in \llbracket 0, H-1 \rrbracket$, $a_i = \pi_\theta(o(x)_i)$ et $x_{i+1} = \delta(x_i, a_i)$, où $\delta : \mathcal{X} \times \mathcal{A} \rightarrow \mathcal{X}$ est la fonction de transition qui calcule l'état suivant x_{i+1} en fonction de l'état courant x_i et de l'action a_i .

Contrairement au cadre classique de l'apprentissage par renforcement, où une récompense est attribuée après chaque action, nous calculons ici une récompense globale pour chaque trajectoire donnée. Cette récompense suit la formulation $R(\pi_\theta, I, x_0, H) = \max_{x \in T(\pi_\theta, I, x_0, H)} f_{\text{obj}}(x)$. Dans ce contexte, concevoir un algorithme efficace de recherche locale pour résoudre un ensemble d'instances revient à déterminer une politique optimale.

3 Expérimentations

Nous évaluons la capacité de notre approche à générer des politiques de recherche locale adaptées à différentes distributions d'instances pseudo-bouliennes. Les expérimentations portent sur des problèmes pseudo-bouliens issus du modèle NK de Kauffman et Weinberger, permettant de contrôler la difficulté, du point de vue des paysages de recherche induits, des instances générées. Plusieurs fonctions d'observation sont définies pour extraire des informations à partir des contextes locaux et globaux au cours de l'optimisation. Voici quelques exemples significatifs de telles fonctions :

- **Observations locales :**
 - $\Delta_i(x) = f_{\text{obj}}(\text{flip}_i(x)) - f_{\text{obj}}(x)$: le score différentiel mesurant l'amélioration apportée par la solution candidate $\text{flip}_i(x)$ par rapport à la solution courante x .
 - $r_i(x, \mathcal{N})$: le rang local de $\text{flip}_i(x)$ parmi les scores différentiels du voisinage courant $\mathcal{N}(x) = \{\text{flip}_i(x) \mid i \in \llbracket 1, N \rrbracket\}$. La fonction r_i préserve le signe du score différentiel et est uniformisée dans les intervalles $[-1, 0[$ et $]0, 1]$.
- **Observations globales :**
 - $r_i(x, \mathcal{M}_t)$: le rang global de $\text{flip}_i(x)$ parmi tous les scores calculés jusqu'à l'itération t , soit $\mathcal{M}_t = \{x_0\} \cup \bigcup_{k=1}^t \{\text{flip}_i(x) \mid i \in \llbracket 1, N \rrbracket\}$. La fonction r_i est normalisée sur $[0, 1]$.
 - b_t : le budget d'optimisation restant à l'itération t , exprimé en fraction de budget total, avec $b_t \in [0, 1]$.
 - tabu_t : une structure à mémoire qui encode les actions récemment effectuées afin d'éviter les retours cycliques, information utilisée par la recherche tabou bien connue.

Les performances des politiques apprises dépendent des combinaisons d'observations, les plus efficaces intégrant à la fois des informations locales et globales. Cette conjonction d'informations permet aux politiques de ne pas rester bloquées dans des optima locaux.

En comparaison avec des procédures de recherche locale déterministes classiques, notre approche obtient des performances équivalentes, voire supérieures, notamment dans les scénarios où une exploration plus diversifiée est cruciale. Nos analyses montrent que les stratégies émergentes adoptent des comportements similaires à ceux d'approches efficaces connues, tout en s'adaptant dynamiquement aux contextes rencontrés.

Références

- [1] Olivier Goudet, Mohamed Salim Amri Sakhri, Adrien Goëffon, and Frédéric Saubion. Emergence of new local search algorithms with neuro-evolution. In *European Conference on Evolutionary Computation in Combinatorial Optimization (Part of EvoStar)*, pages 33–48. Springer, 2024.
- [2] Nikolaus Hansen, Sibylle D. Müller, and Petros Koumoutsakos. Reducing the Time Complexity of the Derandomized Evolution Strategy with Covariance Matrix Adaptation (CMA-ES). *Evolutionary Computation*, 11(1) :1–18, March 2003.
- [3] Holger H Hoos and Thomas Stützle. Stochastic local search. In *Handbook of Approximation Algorithms and Metaheuristics*, pages 297–307. Chapman and Hall/CRC, 2018.