


orchestRAtiNg iNtelligeNce

HETEROGENEOUS SWARMS: マルチLLMシステムにおける役割と重みの同時最適化

スケーリング則の先にある、新たな地平へ

単一巨大モデルの時代は、驚異的な成功と同時に、3つの壁に直面している。



計算コストの壁

- 幾何級数的に増大する学習・推論コスト。
- GPT-4クラスのモデル開発はもはや国家・巨大テック企業の領域。



データの壁

- 高品質な学習データの枯渇。
- インターネット上のテキストを使い果たしつつあるという現実。



能力の壁

- 幻覚（ハルシネーション）の不可避性。
- 単一モデルでは、特定の専門領域における知識の深さに限界。

→ では、次なるパラダイムは何か？ → 「個」から「群」へ。 →


「群れ」のアプローチ、しかしそこには分断があった

Multi-LLM Systems

役割 (Role) の最適化

誰が何をして、どう情報を渡すか？
(グラフ構造の最適化)

Examples: Chain, Star, GPT-Swarm



個々のモデル能力は固定 (ブラックボックス)。最高の楽団員がいても、配置が悪ければ意味がない。

重み (Weight) の最適化

各モデルをどう賢くするか？
(モデルパラメータの適応)

Examples: Model Soups, DARE-TIES, Model Swarms




役割分担や連携は固定。最高の配置でも、楽団員の腕が悪ければ良い演奏はできない。

これまでの研究は、「役割」か「重み」か、どちらか一方しか最適化できていなかった。

HETEROGENEOUS SWARMS: 「役割」と「重み」の同時最適化

最高の「チーム編成」と最高の「メンバー能力」を、同時に見つけ出す。



$$\text{Goal : } \max_{A, X} f(A, X)$$

A : 隣接行列 (Adjacency Matrix)
- モデル間の接続関係を定義


X : モデル重み集合 (Model Weights)
- 各モデルの能力を定義

f : 効用関数 (Utility Function)
- タスクの性能スコア (e.g., 正解率)

最適化のエンジン：粒子群最適化（PSO）

微分不可能な探索空間を、どうやって最適化するのか？

勾配不要の群知能アルゴリズム、PSO。



1. 探索 (Explore):
各粒子（解の候補）が空間を飛び回る。
2. 記憶 (Remember):
 - ・ パーソナルベスト (p_i): 自分が過去に見つけた最高地点
 - ・ グローバルベスト (g): 群れ全体で見つけた最高地点
3. 更新 (Update): 速度 `v` と位置 `x` を更新。
新しい速度 ← (慣性) + (自己ベストへの引力) + (全体ベストへの引力)
$$v_i \leftarrow w \cdot v_i + c1 \cdot r1 \cdot (p_i - x_i) + c2 \cdot r2 \cdot (g - x_i)$$

PSOは「個人の成功体験」と「群全体の成功体験」を頼りに、最適な解を集合的に探索する。

Step 1: Role-step — 最適な「チーム構造」の探索


Goal: モデルの重み (X) を固定し、最適な接続構造 (A) を見つける。

The Challenge:


PSOは連続値 (隣接行列 A) を扱うが、実行するには離散的なグラフ (DAG) が必要。

The Solution:

G-decode アルゴリズム



PSO Loop for Roles



Step 2: Weight-step — 「個々の能力」の最適化

Goal: 最良の構造 A_best を固定し、各モデルの重み x_i を適応させる。

The Challenge


信用割当問題 (Credit Assignment)

- チームの成功に誰がどれだけ貢献したか？

The Solution:

 JFK-score

“Ask not what the multi-LLM system can do for you, ask what you can do for the multi-LLM system.”



JFK-scoreの計算 (The Performance Review)


$$\text{JFK-score}(x_i) = \frac{\sum cnt_{i,j} * f(X_j)}{\sum cnt_{i,j}}$$

(モデル x_i の貢献度は、登場したチームのスコアの重み付き平均)

PSO Loop
for Weights




1. 各モデル x_i が
PSOの粒子



2. JFK-scoreを適応度として、
モデルの重みを更新。

全体像：役割と重みの共進化ループ



役割（構造）と重み（能力）が、互いに影響を与えながらタスクに特化していく。

そして、結果は。

	Knowledge	Reasoning	Agent	Misc.
	MMLU-pro	GSM8k	GAIA-text	GAIA-text
BEST SINGLE	63.9	21.7	25.9	35.2
MODEL SWARMS	82.7	22.6	70.9	40.3
GPT-SWARM	89.8	26.5	97.4	40.6
H-SWARMS	82.5	28.7	81.4	59.5

11/12タスクで最高性能
(SOTA)

2位の手法に対し、
平均 +18.5%
の性能向上

役割(Role)と重み(Weight)の
最適化は、タスクによって
重要度が異なる

「1 + 1 > 2」の証明：協調利得 (Collaborative Gain)


群れで解く価値は本当にあるのか？

C-Gainの定義：個々のLLMが p% しか解けない問題に対し、群れが p% を超えて解ける度合い。

$$\text{C-Gain} = \sum (|B_n|/|D|) * (\text{Acc}(B_n) - \text{EA}(B_n))$$

一貫して正のC-Gain

全ての難易度で、
期待値を上回る性能。




創発的能力

構成員の誰も解けなかった問題 (B_0) のうち、
18.1%を解決。

問題の難易度 (個々のLLMのうち何体が正解できたか？ $n/10$)

成功の鍵は「多様性」にある


専門家のチームは、クローンのチームを凌駕する。




システムが自ら学習する「役割分化」

最適化の過程で、各モデルは自律的に専門家へと進化する。

タスク毎の役割分布



DAG内の位置と役割



Heterogeneous Swarmsがもたらした4つの貢献



設計フレームワーク

マルチLLMシステムの**役割（構造）と重み（能力）を同時に最適化する**、初の統一的枠組みを確立。



G-decode

連続的な隣接行列から離散的なDAGを生成し、**グラフ構造の連続最適化**を可能にした。



JFK-score

個々のモデルの貢献度をスカラー化し、信用割当問題を解決。重み最適化への道を開いた。



実証と分析

広範なタスクで有効性を実証し、**協調利得、多様性の重要性、役割分化**といった新たな知見を提示。