

国産農業用 LLM のための要点抽出における 模伝的アルゴリズムの検討

渋木 英潔¹ 阪本 浩太郎¹ 桂樹 哲雄² 小林 暁雄²

石原 潤一² 大友 将宏²

¹ 株式会社 BESNA 研究所 ² 農研機構 農業情報研究センター

{shib,sakamoto}@besna.institute

{katsuragi.tetsuo797,kobayashi.akio544}@naro.go.jp

{ishihara.junichi964,ohtomo.masahiro841}@naro.go.jp

概要

一般の学生にとって LLM の利用は API を経由した推論が前提でウェイト更新を伴う学習が難しいことが多い。そこで本稿は、LLM の振る舞いを「モデル内部のウェイト=遺伝子」と「モデル外部の離散プロンプト=ミーム (模伝子)」に分け、遺伝子を固定したままミームを進化的に改良する模伝的アルゴリズムを提案する。予備検証として、農業ドメイン QA の要点抽出における 25 件のクローズド環境で実験を行った結果、gpt-5-mini は一般化ケンドール距離で第 1 世代の 0.8313 から第 5 世代 0.6692 へ、gpt-oss-120b は第 1 世代 0.8904 から第 10 世代 0.1996 へと縮まり、gpt-5.2 (第 1 世代 0.7760) を上回った。

1 はじめに

ChatGPT や Gemini といった汎用大規模言語モデル (LLM) が広範な言語能力を示す一方で、医療 [1]、法律 [2]、金融 [3] といった専門分野では語彙分布・文体・前提知識・評価軸などが異なるため、特定ドメインのタスクに適応させるための追加学習や調整が必要となることが多い [4, 5]。農研機構においても、内閣府「研究開発と Society 5.0 との橋渡しプログラム (BRIDGE)」¹⁾の一環として、農業分野に特化した国産 LLM (以下、農業用 LLM) の開発を目指している [6, 7, 8]。

LLM の開発には時間・労力・計算資源が大量に必要であり、農研機構などの組織が率先して取り組むべきであるが、研究の裾野を広げるためには、潤沢なりソースをもたない個人であっても容易にアイデアを試せる仕組みが必要である。近年の LLM 利用

は API ベースの商用サービスへの依存も強まっているが、API 利用では一般に「推論」は可能でも「ウェイト更新を伴う学習」は不可能だったり高額だったりする。したがって、**推論のみで実行可能な適応・最適化手続きの整備は実用上の意義が大きい。**

計算資源を抑えたウェイト更新として PEFT (LoRA[9] や QLoRA[10] 等) が提案されている。また近年は、モデルウェイトを「遺伝子」と見做して進化的最適化を適用する方向性も提案されている [11, 12]。進化的最適化は勾配に依存しない探索として有望である一方、評価のために多数の候補 (ウェイトやマージ結果) を実際に生成・実行する必要があり、多くの場合、オープンウェイトやローカル計算環境を前提とする。すなわち、資源制約下や API 中心の環境においては、ウェイトを探索変数とする手法をそのまま適用することが難しい場合がある。この点で、**探索対象 (候補) の表現が軽量であること**は実用上重要となる。

本稿では LLM の振る舞いを規定する要因を「モデル内部」と「モデル外部」に分解して捉える。具体的には、モデル内部の情報 (ウェイト等) を遺伝子、モデル外部から与えられる言語的情報 (離散プロンプト等) をミーム (模伝子) と見做して、ミームを対象とした進化計算を行う**模伝的アルゴリズム**²⁾を導入する。API 利用を前提とする現実的制約のもとでは遺伝子 (モデル) を固定して、ミーム (プロンプト) を以下の進化的枠組みで改善する (図 1 参照)。(1) 正解を参照してプロンプトを生成する、(2) 現プロンプトで LLM を**推論実行**して出力を得る、(3) 出力と正解との差分に基づき LLM 自身に**プロンプト修正案を生成**させる、(4) 目的関数により

2) LLM 以前の memetic algorithm や離散プロンプト最適化との比較は 2 節で行う。

1) <https://www8.cao.go.jp/cstp/bridge/index.html>

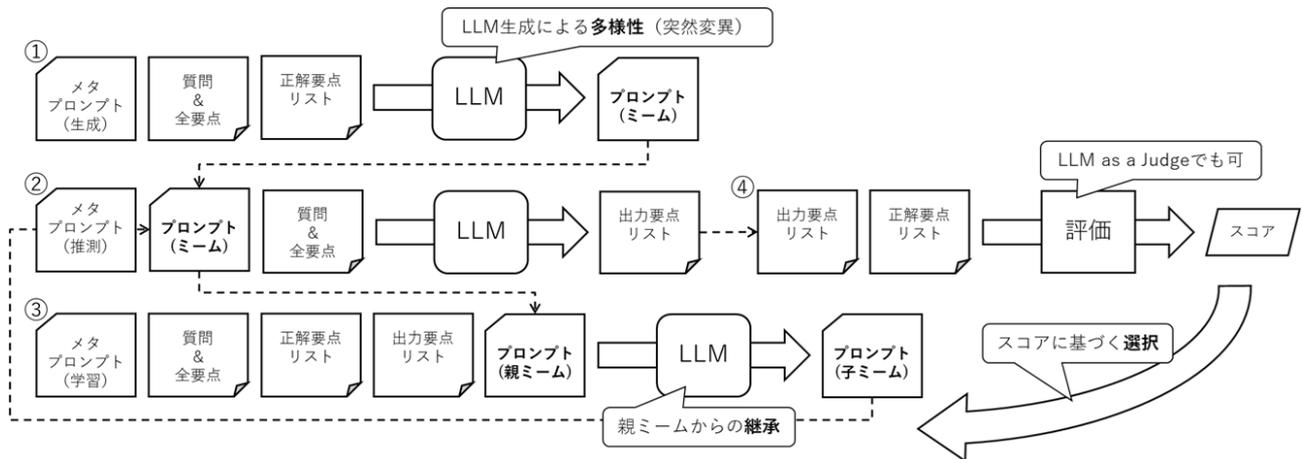


図 1: 模伝的アルゴリズム (最小設定) の流れ

案を**選択・継承**して(2)に戻る、という反復ループでプロンプトを更新する。進化計算の本質は、多様性、選択、継承の3点にある。LLMによる生成はtemperature等を適切に設定することで**突然変異に相当する多様性**が生じるため、模伝的アルゴリズムでは同一の個体から複数の個体を生じうる³⁾。また、必要とする LLM 操作が生成 (推論) 呼び出しのみであり、**勾配計算やウェイトアクセスを必要としない**点も利点である。

本稿は、模伝的アルゴリズムの予備検証の位置づけで、農業ドメイン QA における要点抽出 (順序付きリスト生成) [8] を対象とした最小設定 (各世代で維持するプロンプト数が 1) の実験結果を報告する。

2 関連研究

Dawkins[13] は脳の外へ複製される文化的伝達単位としてミームを導入した。1 節で述べたミームは、この意味で外部表現 (離散プロンプト) の比喻である。一方で、LLM 以前の memetic algorithm[14, 15] は一般に「進化的探索+局所探索 (個体学習)」の枠組みとして整理され、ミームは局所探索手続きの比喻として用いられることが多い。図 1 の (3) に示すように、模伝的アルゴリズムでは次世代のプロンプトを LLM によって指向的に生成しており、memetic algorithm における局所探索に相当する働きをしている。これは改善結果をそのまま遺伝子表現に該当するプロンプトに書き戻して継承するためラマルク型に近い。したがって、この意味でも模伝的アルゴリズムといえる。本稿では用語混同を避けるため、外部表現をタスクミーム、局所探索手続きをメソッドミームと定義する。

3) 交差などによる多様性との併用も可能である

表 1: 要点抽出の例

【質問】	強力品種の「キタノカオリ」は実需にどのような評価を得ていますか？
【回答すべき回答ポイント】	<ol style="list-style-type: none"> 1. 実需での総合評価 (強力粉としての位置づけ) 2. タンパク質含有量とグルテン形成性の特徴 3. パンや麺など用途別の適性 (パン中華麺等) 4. 製麺業者や製パン業者の評価・要望 5. 小麦粉の色沢や風味の評価 6. 製粉適性と灰分や吸水率の傾向 7. 他品種とのブレンド比率と推奨例 8. 収量性と品質安定性の実績 9. 病害虫耐性や栽培上の注意点 10. 収穫時期や乾燥調整の管理ポイント 11. 市場価格動向と取引先の需要傾向 12. 保存性と長期貯蔵時の品質変化
【実際の回答ポイントの記述順】	<ol style="list-style-type: none"> 1. 実需での総合評価 (強力粉としての位置づけ) 5. 小麦粉の色沢や風味の評価 4. 製麺業者や製パン業者の評価・要望 9. 病害虫耐性や栽培上の注意点

学習を伴わずに LLM の振る舞いを変える手段としてプロンプティングがあり、離散プロンプトを最適化する研究が進んでいる。強化学習を用いて離散プロンプトを最適化する RLPrompt[16] や、遺伝的探索により少数例学習のためのプロンプトを探索する GPS[17] が提案されている。さらに、LLM と進化的アルゴリズムを接続して強力なプロンプト最適化を実現する枠組み [18] や、進化的プロンプト探索を改善するためのツールボックス [19] も報告されている。模伝的アルゴリズムはプロンプトを探索変数とする点でこれらと共通するが、先に述べた局所探索の点で異なる。

表 2: 一般化ケンドール距離 (プロンプト行数)

Gen.	gpt-5.2	gpt-5-mini	gpt-oss-120b
1	0.7760 (56)	0.8313 (76)	0.8904 (39)
2	— (-)	0.7525 (95)	0.8109 (79)
3	— (-)	0.7919 (142)	0.8059 (65)
4	— (-)	0.6778 (185)	0.8068 (65)
5	— (-)	0.6692 (187)	0.8082 (65)
6	— (-)	— (-)	0.8333 (52)
7	— (-)	— (-)	0.8917 (59)
8	— (-)	— (-)	0.8960 (57)
9	— (-)	— (-)	0.8917 (58)
10	— (-)	— (-)	0.1996 (126)
11	— (-)	— (-)	0.2294 (126)
12	— (-)	— (-)	0.7472 (127)
13	— (-)	— (-)	0.2396 (77)
14	— (-)	— (-)	0.7082 (77)
15	— (-)	— (-)	0.2294 (78)

3 要点抽出タスク

本稿で対象とする要点抽出タスク⁴⁾の例を表 1 に示す。質問と選択肢である要点一覧 (表中の【回答すべき回答ポイント】) が入力された際に、正解となる順序付き要点リスト (表中の【実際の回答ポイントの記述順】) を出力するタスクである。したがって、LLM に選択肢の中から適切な要点を適切な順序で出力させるためのプロンプトがタスクミームとなる⁵⁾。正解もシステム出力も一部順位付けであるため、一般化ケンドール距離 [20] を [0, 1] に正規化したスコアを評価に用いた⁶⁾。距離であるため小さいほど (0 に近いほど) 良いスコアとなる。

4 実験

本稿では、OpenAI が提供する gpt-5.2、gpt-5-mini、gpt-oss-120b の 3 つのモデル⁷⁾を用いた実験を行った。gpt-5.2 はベースラインの位置づけであり、それより“弱い”モデルである gpt-5-mini と gpt-oss-120b が模伝的アルゴリズムによりどのように学習するかを調査する。費用対効果の観点からは、1M トークンあたりの入力/出力の API 費用⁸⁾が gpt-5.2 の 1.75/14.00 ドルに対して gpt-5-mini は 0.25/2.00 ドルであるため、概算⁹⁾で 7 回以内の呼び出しで同等以

4) タスク自体の詳細は、石原ら [7, 8] を参照されたい。
 5) 図 1 のメタプロンプトについては付録に記述する。
 6) LLM-as-a-Judge[21] を用いることも可能であるが、資源制約を考慮して一般化ケンドール距離を用いた。
 7) 推論モデル (Chain-of-Thought を行う) と非推論モデル (行わない) の間には埋めがたい差があると考えているため推論モデルを前提とした。
 8) <https://platform.openai.com/docs/pricing>
 9) 正確には実際の入出力トークン量を計算する必要がある。本稿の範囲では特にトークン量の変化は見られなかった。

表 3: 第 1 世代のミーム (gpt-5-mini)

ルール:
1) 概念的な前提 (用語) - 「質問の主目的」= 回答で最優先すべき観点 (評価・数値推奨・作業時期・診断・薬剤有効性・モニタリング等)。- 各「回答すべき回答ポイント」は文言から意味タグ (例: 総合評価/タンパク・グルテン特性/用途適性/業者評価/色沢・風味/施肥総量数値/土壌特性/N と蛋白の関係/追肥回数・段階配分/ラベル (希釈・回数)/薬剤有効性・作用機序/耐性対策 (ローテーション)/散布時期/NDVI 時系列解析/閾値設定/現地校正/等) を付与すること。
2) 質問分類 (キーワード→カテゴリ) - 市場・実需評価系: 語句に「評価」「実需」「官能」「どちらが…高い」等- 施肥/窒素バランス系: 語句に「窒素」「タンパク」「減肥」「倒伏を防ぐ」「バランス」等- 農薬有効性系: 語句に「有効ですか」「散布」「剤名」「水和剤」等- リモートセンシング・データ系: 語句に「NDVI」「人工衛星」「データ」等- 作業時期系: 語句に「時期」「いつが適正」「雪上施肥」等- 倒伏対策・栽培法系: 語句に「倒伏」「栽培方法」「防ぐ」等- 病害発生分布・診断系: 語句に「どのエリア」「発生」「感染状況」「症状」等- 播種・適期計算法系: 語句に「播種適期」「気温に基づく計算」「GDD」「発芽温度」等- 残渣・土壌改良系: 語句に「残渣」「有材」「土層改良」「再施工頻度」等- 推定・計算系: 語句に「推定」「計算式」「方法」等 (略)
10) 出力順序決定アルゴリズム (総合) - (a) 質問をカテゴリ分類→(b) 各「回答すべき回答ポイント」を意味タグ付与→(c) A で定義した「必須選択群」を抽出→(d) B の支援タグを追加→(e) トレードオフなら網羅、でなければカテゴリ別優先順位に基づき上位から所定数 (既定は 3、カテゴリにより 4) を選ぶ→(f) 選んだ項目を「直接的行動 (数値/時期/結論) →安全/規制→因果の根拠→実務手順→リスク・代替→検証」の順に並べ、同順位は原順で決定。(以上)

上の効果が得られるかが分岐点となる。予算の都合上、gpt-5.2 は第 1 世代 (図 1 の (1) のみ)、gpt-5-mini は第 5 世代までとした。gpt-oss-120b は、ローカル計算環境での実行のため 15 世代まで行った。全てのモデルで、temperature=0.7、reasoning_effort=high、max_tokens=128k とした。予備検証の段階のため、質問数 25 件のクローズド環境での実験である。

表 2 に各世代のプロンプトを用いて要点抽出した 25 件の結果に対する一般化ケンドール距離の平均スコアを示す。また、各世代のプロンプトの複雑さに関する参考指標としてプロンプトの行数を括弧内に示す。第 1 世代では gpt-5.2 の 0.7760 が最も良く、モデル性能と連動する結果となった。しかし、第 2 世代の時点で gpt-5-mini が 0.7525 とベースラインを上回り、その後も距離を縮めていくことで第 5 世代では 0.6692 となった。1 世代あたり API 呼び出しが 2 回 (図 1 の (2) と (3)) 増加するが、費用対効果は gpt-5-mini の方が良いといえる。第 1 世代と第 5 世代のプロンプト (タスクミーム) の一部を表 3 と表 4 にそれぞれ示す。どちらも「概念的な前提」から始まり「出力順序決定アルゴリズム」で終わっているが、第 5 世代では「4) カテゴリ別 優先選択列」が新

研究の一部は、農研機構の AI 研究用スーパーコンピュータ「紫峰」を利用して実施した。

参考文献

- [1] Zetian Ouyang, Yishuai Qiu, Linlin Wang, Gerard De Melo, Ya Zhang, Yanfeng Wang, and Liang He. CliMedBench: A large-scale Chinese benchmark for evaluating medical large language models in clinical scenarios. In Yaser Al-Onaizan, Mohit Bansal, and Yun-Nung Chen, editors, **Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing**, pp. 8428–8438, Miami, Florida, USA, November 2024. Association for Computational Linguistics.
- [2] Zhiwei Fei, Xiaoyu Shen, Dawei Zhu, Fengzhe Zhou, Zhuo Han, Alan Huang, Songyang Zhang, Kai Chen, Zhixin Yin, Zongwen Shen, Jidong Ge, and Vincent Ng. LawBench: Benchmarking legal knowledge of large language models. In Yaser Al-Onaizan, Mohit Bansal, and Yun-Nung Chen, editors, **Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing**, pp. 7933–7962, Miami, Florida, USA, November 2024. Association for Computational Linguistics.
- [3] Yong Xie, Karan Aggarwal, and Aitzaz Ahmad. Efficient continual pre-training for building domain specific large language models. In Lun-Wei Ku, Andre Martins, and Vivek Srikumar, editors, **Findings of the Association for Computational Linguistics: ACL 2024**, pp. 10184–10201, Bangkok, Thailand, August 2024. Association for Computational Linguistics.
- [4] Suchin Gururangan, Ana Marasović, Swabha Swayamdipta, Kyle Lo, Iz Beltagy, Doug Downey, and Noah A. Smith. Don’t stop pretraining: Adapt language models to domains and tasks. In Dan Jurafsky, Joyce Chai, Natalie Schluter, and Joel Tetreault, editors, **Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics**, pp. 8342–8360, Online, July 2020. Association for Computational Linguistics.
- [5] Chengyuan Liu, Yangyang Kang, Shihang Wang, Lizhi Qing, Fubang Zhao, Chao Wu, Changlong Sun, Kun Kuang, and Fei Wu. More than catastrophic forgetting: Integrating general capabilities for domain-specific LLMs. In Yaser Al-Onaizan, Mohit Bansal, and Yun-Nung Chen, editors, **Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing**, pp. 7531–7548, Miami, Florida, USA, November 2024. Association for Computational Linguistics.
- [6] 桂樹哲雄, 小林暁雄, 坂地泰紀. 農研機構における農業用生成 ai 構築の取り組み 日本語言語資源の構築と利用性の向上. JLR2024 ワークショップ, 2024.
- [7] 石原潤一, 小林暁雄, 桂樹哲雄, 大友将宏, 橋本祥, 阪本浩太郎, 杉村安都武, 米丸淳一, 安藤まや, 後藤美智子, 関根聡, 川村隆浩. 国産農業用 llm のためのインストラクションデータ構築と構築された llm システムの評価. 言語処理学会第 31 回年次大会 発表論文集, 長崎, March 2025. 言語処理学会. NLP2025.
- [8] 石原潤一, 小林暁雄, 桂樹哲雄, 大友将宏, 橋本祥, 阪本浩太郎, 杉村安都武, 米丸淳一, 川村隆浩. 国産農業用 llm のための要点抽出方法に基づく評価手法の検討. 人工知能学会全国大会論文集, Vol. JSAI2025, p. 1P4OS1b03, May 2025.
- [9] Edward J. Hu, Yelong Shen, Phillip Wallis, Zeyuan Allen-Zhu, Yuanzhi Li, Shean Wang, Lu Wang, and Weizhu Chen. Lora: Low-rank adaptation of large language models. In **International Conference on Learning Representations (ICLR)**, 2022.
- [10] Tim Dettmers, Artidoro Pagnoni, Ari Holtzman, and Luke Zettlemoyer. Qlora: Efficient finetuning of quantized llms. In **Advances in Neural Information Processing Systems (NeurIPS)**, 2023.
- [11] Guodong Du, Jing Li, Hanting Liu, Runhua Jiang, Shuyang Yu, Yifei Guo, Sim Kuan Goh, and Ho-Kin Tang. Knowledge fusion by evolving weights of language models. In Lun-Wei Ku, Andre Martins, and Vivek Srikumar, editors, **Findings of the Association for Computational Linguistics: ACL 2024**, pp. 11727–11742, Bangkok, Thailand, August 2024. Association for Computational Linguistics.
- [12] Takuya Akiba, Makoto Shing, Yujin Tang, et al. Evolutionary optimization of model merging recipes. **Nature Machine Intelligence**, Vol. 7, pp. 195–204, 2025. Published: 27 Jan 2025 (Issue date: Feb 2025).
- [13] Richard Dawkins. **The Selfish Gene**. Oxford University Press, 1976. Introduces the concept of the “meme” as a unit of cultural transmission.
- [14] Pablo Moscato. On evolution, search, optimization, genetic algorithms and martial arts: Towards memetic algorithms. Technical Report 158-79, California Institute of Technology, Caltech Concurrent Computation Program, Pasadena, CA, USA, 1989. Tech. report. (Often cited with report-number variants in later literature.)
- [15] Natalio Krasnogor and Jim Smith. A tutorial for competent memetic algorithms: Model, taxonomy, and design issues. **IEEE Transactions on Evolutionary Computation**, Vol. 9, No. 5, pp. 474–488, 2005.
- [16] Mingkai Deng, Jianyu Wang, Cheng-Ping Hsieh, Yihan Wang, Han Guo, Tianmin Shu, Meng Song, Eric Xing, and Zhiting Hu. RLPrompt: Optimizing discrete text prompts with reinforcement learning. In Yoav Goldberg, Zornitsa Kozareva, and Yue Zhang, editors, **Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing**, pp. 3369–3391, Abu Dhabi, United Arab Emirates, December 2022. Association for Computational Linguistics.
- [17] Hanwei Xu, Yujun Chen, Yulun Du, Nan Shao, Wang Yanggang, Haiyu Li, and Zhilin Yang. GPS: Genetic prompt search for efficient few-shot learning. In Yoav Goldberg, Zornitsa Kozareva, and Yue Zhang, editors, **Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing**, pp. 8162–8171, Abu Dhabi, United Arab Emirates, December 2022. Association for Computational Linguistics.
- [18] Qingyan Guo, Rui Wang, Junliang Guo, Bei Li, Kaitao Song, Xu Tan, Guoqing Liu, Jiang Bian, and Yujiu Yang. Connecting large language models with evolutionary algorithms yields powerful prompt optimizers. In **The Twelfth International Conference on Learning Representations**, 2024.
- [19] Daniel Grißhaber, Maximilian Kimmich, Johannes Maucher, and Thang Vu. A toolbox for improving evolutionary prompt search. In Henrique Lopes Cardoso, Rui Sousa-Silva, Maarit Koponen, and Antonio Pareja-Lora, editors, **Proceedings of the 2nd LUHME Workshop**, pp. 58–66, Bologna, Italy, October 2025. UP - Universidade do Porto (<https://doi.org/10.21747/978-989-9193-73-4/lan2>), LIACC - Laboratório de Inteligência Artificial e Ciência de Computadores da Universidade do Porto, CLUP - Centro de Linguística da Universidade do Porto, UEF - The University of Eastern Finland and UAH - Universidad de Alcalá.
- [20] Ronald Fagin, Ravi Kumar, and D. Sivakumar. Comparing top k lists. **SIAM Journal on Discrete Mathematics**, Vol. 17, No. 1, pp. 134–160, 2003.
- [21] Lianmin Zheng, Wei-Lin Chiang, Ying Sheng, Siyuan Zhuang, Zhanghao Wu, Yonghao Zhuang, Zi Lin, Zhuohan Li, Dacheng Li, Eric P. Xing, Hao Zhang, Joseph E. Gonzalez, and Ion Stoica. Judging llm-as-a-judge with mt-bench and chatbot arena. **CoRR**, Vol. abs/2306.05685, , 2023.
- [22] Yikun Guo, Fuliang Weng, and Lide Wu. Grammar induction by MDL-based distributional classification. In **Proceedings of the Seventh International Workshop on Parsing Technologies**, pp. 112–122, Beijing, China, October 2001.

表6: メタプロンプト (生成)

あなたは人間の心理、特に選好を言語化する専門家です。質問応答において、【回答ポイント】とは、質問者の意図を酌んだ回答をするための観点で、例えば、友人から「今、何しているの?」という質問を受けた場合は、「ボウリングしている」や「宿題している」といった直接の回答だけでなく、「一緒に遊びたい」という友人の意図を酌んで「近くのボウリング場だから来ない?」といった【集合場所の提示】や「今日は無理だから明日はどう?」といった【次回の予定】などの観点からの回答が考えられます。「回答すべき回答ポイント」は、その「質問」から一般的に考えられる回答ポイントのリストで、「実際の回答ポイントの記述順」は、ある同一回答者の実際の回答に含まれる回答ポイントをその記述順に並べたものです。「どの回答ポイントを選択するか」や「どの順番で記述するか」といった回答者の選好を、以下の「質問」と「回答すべき回答ポイント」と「実際の回答ポイントの記述順」のリストから推測しルールとして言語化してください。ルールは精度(選好の再現性)を最も重視します。精度が良くなるのであれば、ルールの長さや読みやすさは無視して良いです。ルール以外は出力しないでください。

A メタプロンプト

図1の(1)から(3)で用いられるメタプロンプトを表6から表8にそれぞれ示す。メタプロンプトの後ろにタスクミームや質問・要点リストなどを連結してLLMに投げている。世代が変わってもメタプロンプトは変更されない。

メソッドミームがラマルク的な模伝的アルゴリズムになっているのは、表8のメタプロンプト(学習)において「出力が正解と一致するように」と指示しているからである。したがって、「ランダムに」交差なり突然変異なりするよう指示すれば、従来研究における「遺伝的アルゴリズムによる離散プロンプト最適化」を行うことになる。しかしながら、現時点の資源制約下での探索ではその必要性を感じていない。

将来的な可能性の話であるが、離散プロンプトを個体、LLMを環境(世界)と見做せば、メタプロンプトは世界での在り方を定義する法則にあたるため、例えば、「親ミームを“3”つ選択し、それら全ての特徴を併せ持った子ミームを生成する」といったように、自由な発想による法則で進化計算を行うことができるかもしれない。

表7: メタプロンプト (推測)

あなたは人間の心理、特に選好を考慮した質問応答システムです。質問応答において、【回答ポイント】とは、質問者の意図を酌んだ回答をするための観点で、例えば、友人から「今、何しているの?」という質問を受けた場合は、「ボウリングしている」や「宿題している」といった直接の回答だけでなく、「一緒に遊びたい」という友人の意図を酌んで「近くのボウリング場だから来ない?」といった【集合場所の提示】や「今日は無理だから明日はどう?」といった【次回の予定】などの観点からの回答が考えられます。「回答すべき回答ポイント」は、その「質問」から一般的に考えられる回答ポイントのリストですが、「どの回答ポイントを選択するか」や「どの順番で記述するか」といった回答者の選好により、実際の回答に含まれる回答ポイントの数や記述順は異なります。以下の「選好ルール」に基づいて、「質問」と「回答すべき回答ポイント」の250組それぞれに対して、実際に回答する際に含める回答ポイントを(番号のみ)記述順に出力してください。選好ルールに従うと実際の回答に含めたい回答ポイントが「回答すべき回答ポイント」の中に1個もないと判断した場合は-1を出力してください。## 出力形式
回答ポイントの番号
...

表8: メタプロンプト (学習)

あなたは人間の心理、特に選好を言語化する専門家です。質問応答において、【回答ポイント】とは、質問者の意図を酌んだ回答をするための観点で、例えば、友人から「今、何しているの?」という質問を受けた場合は、「ボウリングしている」や「宿題している」といった直接の回答だけでなく、「一緒に遊びたい」という友人の意図を酌んで「近くのボウリング場だから来ない?」といった【集合場所の提示】や「今日は無理だから明日はどう?」といった【次回の予定】などの観点からの回答が考えられます。「回答すべき回答ポイント」は、その「質問」から一般的に考えられる回答ポイントのリストですが、「どの回答ポイントを選択するか」や「どの順番で記述するか」といった回答者の選好により、実際の回答に含まれる回答ポイントの数や記述順は異なります。「実際の回答ポイントの記述順」は、ある同一回答者の実際の回答に含まれる回答ポイントをその記述順に並べたものです。「推測された回答ポイントの記述順」は、現在の「選好ルール」に基づいて実際の回答に含めたい回答ポイントに回答への記述順に並べたものです(ルールの推測時には「実際の回答ポイントの記述順」は参照できない)。以下の「質問」と「回答すべき回答ポイント」と「実際の回答ポイントの記述順」と「推測された回答ポイントの記述順」のリストを参照して、各質問における「実際の回答ポイントの記述順」と「推測された回答ポイントの記述順」が一致(個数、順序)するよう、以下の「選好ルール」をリファイン(「質問」と「回答すべき回答ポイント」と「選好ルール」の3つだけから「実際の回答ポイントの記述順」を推測できるように)してください。リファイン後のルールのみを用いて推測します。リファイン前のルールは参照しないので、リファイン後のルールだけでリファイン前の回答ポイントも正しく推測できるように記述してください。ルールは精度(選好の再現性)を最も重視します。精度が良くなるのであれば、ルールの長さや読みやすさは無視して良いです。リファインしたルール以外は出力しないでください。