

小規模言語モデルによる広告文生成におけるパーソナライズと不適切性リスクの両立

鈴木 明作

c5614072@gmail.com

概要

推薦システムのプッシュ通知・広告文ではユーザ属性に基づくパーソナライズが有効だが、ユーザ×商品ごとに LLM を運用するのはコスト面で困難になり得る。SLM は低コストだがゼロショットでは属性を無理に挿入し、日本語が不自然な広告文を生成しやすい。本研究では、個別化／汎用化を切り替える選択的パーソナライズ広告文生成を扱い、LLM 審判で作成した蒸留データにより SLM を SFT する枠組みを提案する。さらに根拠を付与する根拠付き蒸留 (CoT-SFT) を導入し、Coverage・Risk・魅力度で評価した。実験の結果、CoT-SFT は単純 SFT より Coverage を抑えつつ Risk を最小化し、魅力度も維持できた。

1 はじめに

推薦システムにおけるプッシュ通知・広告文は、ユーザの関心を喚起し行動を促す重要な要素であり、ユーザ属性や嗜好に合わせたパーソナライズは効果的である。しかし、ユーザ数と商品数が大きい場合、ユーザ×商品ごとに LLM 推論を行う運用は費用面で現実的でないことがある。一方、ローカル実行可能な SLM による生成はコスト面で有望であるが、ゼロショットでは過度にパーソナライズしようとして広告文が不自然な日本語になるなど、運用上好ましくない出力が混入する課題がある。

本研究では、「常にパーソナライズする」ことを目的とせず、パーソナライズすべき場合と汎用文を生成すべき場合を切り替える問題として捉える（選択的パーソナライズ）。具体的には、LLM 審判がユーザ情報および商品情報からパーソナライズ可否を判定し、不適切（不自然な日本語）と判断される場合には、商品情報のみから汎用文を生成し、その結果を蒸留データとして SLM に学習させる。また、蒸留時に根拠 (rationale) を付与する学習 (CoT-SFT)

を導入し、個別化率 (Coverage) と不適切性リスク (Risk) の両面から評価する。

本稿の貢献は以下である。

- 推薦広告文生成を選択的パーソナライズの観点で整理し、個別化率 (Coverage) と不適切性リスク (Risk) で評価する枠組みを示す。
- LLM 審判に基づく蒸留データ構築と SLM 学習により、低コスト運用を想定しつつ不適切な広告文生成を抑制する枠組みを提案する。
- 単純な蒸留 SFT と根拠付き蒸留 SFT (CoT-SFT) を比較し、CoT-SFT が Coverage を抑えつつ Risk を低減し、魅力度を維持することを示す。

2 関連研究

LLM を用いた生成は広告文・推薦メッセージ生成にも応用されており、検索連動型広告文生成の実証研究 [10] や、魅力度を考慮した広告文生成データセットの提案 [11] が報告されている。一方で、ユーザ属性を無理に反映させる過剰な個人化は、不自然な日本語や意味の破綻を誘発し得るため、実運用上のリスクとなり得る。

不確実な場合に生成を抑制したり安全側に倒す選択的生成 (abstention / selective generation) は、品質や安全性を重視する生成設定と親和的であり、自己評価に基づく選択的生成の改善 [8] や、LLM の棄権行動を整理したサーベイ [9] がある。また、大モデルの判断・生成を小モデルへ移す蒸留学習や SFT は運用コスト削減と品質確保に有用であり、根拠を含む推論を蒸留する研究も報告されている [1, 2]。

評価の観点では、LLM-as-a-judge による自動評価が広く用いられている [4, 5]。本研究はこれらの潮流を踏まえ、推薦広告文という応用領域で「選択的パーソナライズ」を中心課題として扱い、不適切性リスク (Risk) と魅力度の観点から根拠付き蒸留の有効性を検証する点に特徴がある。

3 タスク設定

入力はユーザ属性 U と商品情報 I である。出力は、(1) PERSONALIZED/GENERIC の判定と、(2) 広告文 m から構成される。PERSONALIZED は U と I の双方を用いて、ユーザに合わせた個別化文を生成する設定である。一方、GENERIC はユーザ属性を用いず、商品情報 I のみに基づく汎用文を生成する。本稿では、PERSONALIZED と判定される割合を個別化率 (Coverage) として測定する。また、過度な個人化によって広告文が日本語として不自然になることを主要な運用リスクと捉え、その程度を不適切性リスク (Risk) として評価する。さらに、リスク低減による訴求力低下の有無を確認するため、魅力度についても併せて報告する。

4 提案手法

4.1 蒸留データ構築

まず、ユーザ属性 U と商品情報 I を準備し、コンテンツベース推薦によりユーザごとに1つの候補商品を紐づける。ここで、ユーザ情報および商品情報を text-embedding-3-large によりベクトル化し、両者の類似度に基づいてユーザに対するレコメンド商品を決定した。また、商品情報が極端に少ない (タイトル・説明文の情報量が乏しい) 商品は、類似度計算および後段の広告文生成において適切な根拠が得られない可能性があるため、前処理として削除した。

次に、LLM 審判にユーザ属性 U と商品情報 I のレコメンドペアを入力し、(1) パーソナライズ可否判定 y 、(2) 最終広告文 m を得る。このとき、 U と I の対応からパーソナライズが困難または不適切と判断される場合には、 U を用いず I のみに基づく汎用文を生成する。これらにより $\langle U, I \rangle \rightarrow \langle y, m \rangle$ の蒸留データを作成する。

4.2 SLM 学習 (単純な蒸留 / 根拠付き蒸留)

蒸留データにより SLM を教師あり学習する (SFT)。比較として以下を用意する。

- **SFT (単純な蒸留)** : 教師出力は PERSONALIZED or GENERIC + 広告文のみ。
- **CoT-SFT (根拠付き蒸留)** : 教師出力に PERSONALIZED or GENERIC + 根拠 + 広告文を含める。CoT-SFT は推論時も PERSONALIZED or

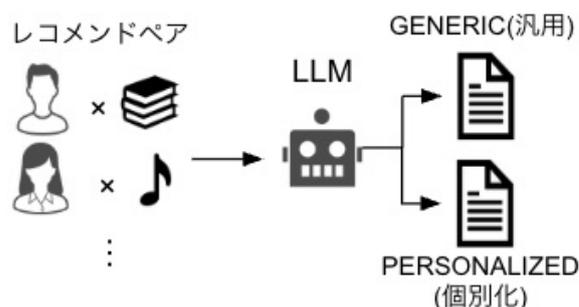


図1 蒸留データセット作成

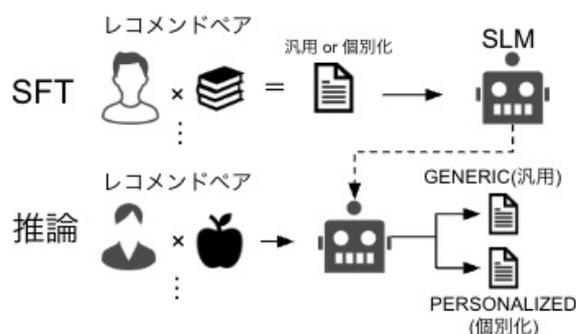


図2 教師あり学習および推論

GENERIC + 根拠+ 広告文 を出力する設定とし、評価では出力中の 広告文 部分のみを抽出して適切性・魅力度を判定した。

5 実験設定

5.1 データ

ユーザデータは、gpt-4.1 を用いて合成生成した 1000 ユーザ (年齢・性別・住所・趣味) を用いる。商品データは公開データセットである Amazon-M2[3] から日本語商品情報を抽出して用いる。ユーザ単位のランダム分割を行い、ユーザの 80% を学習、20% を検証に使用した。検証では 200 サンプルに対して評価を実施した。

5.2 モデル

SLM として Qwen2.5-7B-Instruct を用いた (ゼロショットおよび SFT)。蒸留データ作成における LLM 審判および、LLM-as-a-judge による品質評価 (Coverage 算出のための個別化判定、および適切性・魅力度) には gpt-4.1 を用いた。

6 評価方法

6.1 Coverage (個別化率)

各手法の出力に対し、LLM-as-a-judge が PERSONALIZED/GENERIC を判定し、PERSONALIZED 率を Coverage とした。Coverage 判定では、出力中の PERSONALIZED/GENERIC (および根拠) を除去し、広告文本体のみを入力して個別化判定した。

6.2 Risk (不適切性)

本研究における主要リスクは、過度なパーソナライズにより広告文が「不自然な日本語」になることである。そこで適切性 (Appropriateness) を「広告文が日本語として意味が通り、不自然な表現になっていないか」と定義し、その低さを不適切性リスク (Risk) として扱う。LLM-as-a-judge による適切性の絶対評価スコア (1-5) の平均を \bar{A} とし、

$$\text{Risk} = 5 - \bar{A}$$

と定義する (小さいほど良い)。

6.3 魅力度

広告文としての訴求力を魅力度として評価した。魅力度は LLM-as-a-judge により 5 段階の絶対評価 (平均) で評価した。補助評価として、三者比較 (Zeroshot/SFT/CoT-SFT) で最良の文を選択する相対評価 (Top-1 選択率) も報告する。

7 結果

7.1 Coverage-Risk と魅力度 (絶対評価)

表 1 に Coverage-Risk と魅力度 (絶対評価) を示す。Zeroshot は Coverage が一定程度ある一方、Risk が高く (不自然な日本語が相対的に多く)、魅力度も低い。SFT は Risk を大きく低減し魅力度も改善したが、Coverage が高くなり、より積極的に PERSONALIZED を選択する傾向が見られた。CoT-SFT は SFT より Coverage を抑えつつ、Risk を最小化し魅力度も最も高い結果となり、品質と個別化制御の観点で最もバランスが取れていることが示唆される。

表 1 Coverage-Risk と魅力度 (絶対評価)

Method	Coverage(%)	Risk(=5- \bar{A})	Attractiveness
Zeroshot	68.5	1.290	3.225
SFT	88.5	0.215	3.760
CoT-SFT	80.0	0.175	3.845

表 2 相対評価 (Top-1 選択率; 大きいほど良い)

Method	適切性 (Top-1)	魅力度 (Top-1)
Zeroshot	0.105	0.18
SFT	0.400	0.49
CoT-SFT	0.495	0.33

7.2 適切性と魅力度 (相対評価)

表 2 に相対評価 (Top-1 選択率) を示す。適切性の相対評価では CoT-SFT が最も高い。魅力度の相対評価では SFT が最も高いが、CoT-SFT も Zeroshot より高い。

定性分析として、Zeroshot と SFT/CoT-SFT の出力差を付録 A に示す。

8 考察

8.1 Zeroshot と蒸留 SFT の差

Zeroshot は個別化率が一定程度あるものの、Risk が高く魅力度も低い。これはユーザ属性の挿入により文が不自然になり得ることを示唆する。蒸留 SFT は Risk を大幅に低減し魅力度も改善しており、SLM 運用における実用的な候補である。

8.2 SFT 個別率と CoT-SFT の位置付け

SFT は Risk 低減と魅力度改善に有効だが、Coverage が高く PERSONALIZED を選びやすい。CoT-SFT は Coverage を抑えつつ Risk を最小化し魅力度も維持したことから、根拠付き蒸留が個別化の適用を校正し、文の自然さを改善した可能性が示唆される。

8.3 限界

本研究には以下の限界がある。(1) ユーザ属性は合成データであり、実運用ログでの外的妥当性検証が必要である。(2) 評価は LLM-as-a-judge に依存し、長さ等のバイアスの可能性がある [6, 7]。(3) 本稿の Risk は日本語の自然さ (適切性) に焦点を当てており、事実性やプライバシー観点の評価は今後の課題である。

9 おわりに

本研究では、推薦広告文生成を選択的パーソナライズとして捉え、LLM 審判に基づく蒸留データ構築と SLM の SFT により、低コスト運用を想定しつつ不適切な広告文生成（不自然な日本語）を抑制する枠組みを提案した。実験の結果、根拠付き蒸留 (CoT-SFT) は単純な SFT より Coverage を抑えながら Risk を最小化し、広告文の訴求力 (魅力度) も維持できることを確認した。

参考文献

- [1] Jason Wei et al. Chain-of-Thought Prompting Elicits Reasoning in Large Language Models. **arXiv preprint arXiv:2201.11903**, 2022.
- [2] Cheng-Yu Hsieh et al. Distilling Step-by-Step: Outperforming Larger Language Models with Less Training Data and Smaller Model Sizes. **arXiv preprint arXiv:2305.02301**, 2023.
- [3] Wei Jin, Haitao Mao, Zheng Li, Haoming Jiang, Chen Luo, Hongzhi Wen, Haoyu Han, Hanqing Lu, Zhengyang Wang, Ruirui Li, Monica Xiao Cheng, Rahul Goutam, Haiyang Zhang, Karthik Subbian, Suhang Wang, Yizhou Sun, Jiliang Tang, Bing Yin, and Xianfeng Tang. Amazon-M2: A Multilingual Multi-locale Shopping Session Dataset for Recommendation and Text Generation. **arXiv preprint arXiv:2307.09688**, 2023.
- [4] Yang Liu, Dan Iter, Yichong Xu, Shuohang Wang, Ruochen Xu, and Chenguang Zhu. G-Eval: NLG Evaluation using GPT-4 with Better Human Alignment. **arXiv preprint arXiv:2303.16634**, 2023.
- [5] Lianmin Zheng et al. Judging LLM-as-a-Judge with MT-Bench and Chatbot Arena. **arXiv preprint arXiv:2306.05685**, 2023.
- [6] Yann Dubois, Balázs Galambosi, Percy Liang, and Tatsunori B. Hashimoto. Length-Controlled AlpacaEval: A Simple Way to Debias Automatic Evaluators. **arXiv preprint arXiv:2404.04475**, 2024.
- [7] Keita Saito et al. Verbosity Bias in Preference Labeling by Large Language Models. **arXiv preprint arXiv:2310.10076**, 2023.
- [8] Jie Ren, Yao Zhao, Tu Vu, Peter J. Liu, and Balaji Lakshminarayanan. Self-Evaluation Improves Selective Generation in Large Language Models. In **NeurIPS 2023 Workshops**, PMLR 239:49–64, 2023.
- [9] Bingbing Wen et al. A Survey of Abstention in Large Language Models. **arXiv preprint arXiv:2407.18418**, 2024.
- [10] Hidetaka Kamigaito et al. An Empirical Study of Generating Texts for Search Engine Advertising. In **NAACL-HLT 2021 Industry Track**, 2021.
- [11] Soichiro Murakami et al. AdParaphrase v2.0: Generating Attractive Ad Texts Using a Preference-Annotated Paraphrase Dataset. **arXiv preprint arXiv:2505.20826**, 2025.

表 3 定性例 (原文)

例 1
ユーザ情報 年齢:64 性別: 男性 住所: 愛知県杉並区 職業: 公務員 趣味: 写真撮影
商品情報 商品タイトル:Mr. カラー C113 RLM04 イエロー 商品説明文: 対象年齢: 大人
Zeroshot の広告文 64 歳の公務員さん、写真撮影の際の MMdd おすすめ！イエローの Mr. カラーです
SFT の広告文 写真撮影好きなあなたに！鮮やかなイエローで作品を彩る Mr. カラー
CoT-SFT の広告文 写真撮影好きのあなたに！鮮やかなイエローで作品を彩る
例 2
ユーザ情報 年齢 35, 女性, 住所: 福岡県大田区, 職業: エンジニア, 趣味: ヨガ・カラオケ
商品情報 商品タイトル: ファンケル (FANCL) (新) 40 代からのサプリメント女性用 15~30 日分 (30 袋) 年代サプリ (ビタミン/ミネラル/乳酸菌) 個包装 ...
Zeroshot の広告文 40 代女性エンジニアさん、ヨガも楽しむあなたへ。ファンケルサプリ、手軽にビタミン
SFT の広告文 ヨガやカラオケの後、毎日手軽に健康をサポート！
CoT-SFT の広告文 40 代女性にうれしいサプリ！毎日の健康をサポートします。
例 3
ユーザ情報 年齢 66, 男性, 住所: 愛知県港区, 職業: 医師, 趣味: ゲーム・ガーデニング・音楽鑑賞
商品情報 商品タイトル: ホビーベース オオキナトソウベース 2 コミュウ ホビーヨウトソウコウグ ピーピーシー エヌ 08...
Zeroshot の広告文 ゲーム好き医師さん、ガーデニングにピーピーシーのオオキナトソウベースどう？
SFT の広告文 ガーデニング好きな医師に！細部までこだわったトソウベース
CoT-SFT の広告文 ガーデニング好きのあなたに！便利なトソウコで作業をもっと楽しく。

A 定性分析の例

本付録では、3手法 (Zeroshot/SFT/CoT-SFT) の出力例を示す。ユーザ情報は合成データであり、3手法とも同一入力 (ユーザ情報・商品情報) に対する出力である。いずれの例でも3手法は PERSONALIZED 判定である。Zeroshot では属性 (年齢・職業等) を文頭で名指しする呼びかけ (例: 「40 代女性エンジニアさん、…」) が不自然になり得る。一方、SFT および CoT-SFT では属性を過度に名指しせず、趣味や利用文脈に自然に接続できており、適切性が改善している。

B 学習設定 (LoRA による SFT)

表 4 に学習設定を示す。

LoRA 設定: $r = 16$, $\alpha = 16$, dropout= 0.05, bias=none, target modules={q_proj, k_proj, v_proj, o_proj, gate_proj, up_proj, down_proj}.

表 4 SFT 学習設定 (共通)

項目	設定
Base SLM	Qwen2.5-7B-Instruct
Fine-tuning	LoRA
Epoch	1
Learning rate	1×10^{-4}
Train batch size	1
Gradient accumulation	8
Max length	2048
Optimizer	paged_adamw_8bit
LR scheduler	linear
Warmup ratio	0.1
Weight decay	0.01
Seed	42

C 生成プロンプト (共通部抜粋)

各手法 (Zeroshot / SFT / CoT-SFT) で指示の細部 (例: 根拠出力の有無) は異なるが、共通の指示骨格は以下である。

"1on1 マーケティングのためにはユーザへパーソナライズが重要のため、以下のユーザ情報と商品情報を使って、ユーザにパーソナライズした広告文生成してください。

広告文生成ルール

<事実性>

- ・ユーザ情報と商品情報に含まれる事実に基づく広告文生成をしてください。

<パーソナライズ性>

- ・ユーザ情報と商品情報を使ってパーソナライズが可能な場合には、ユーザにパーソナライズした広告文を生成してください。

- ・一方で、もしユーザ情報と商品情報を使ってパーソナライズが難しい場合 (例: 商品の訴求ポイントとユーザ情報への紐づけが難しい場合) には、ユーザ情報は使わずに商品情報だけを使って広告文を生成してください。

<魅力度>

- ・ユーザが商品を閲覧もしくは購入したくなるような魅力的な広告文生成をしてください。"