

DialFill-Select : 知識指向対話における 対話穴埋め型知識選択モデル

薛強 滝口 哲也 有木 康雄

神戸大学大学院システム情報学研究科

xueqiang@stu.kobe-u.ac.jp, {takigu,ariki}@kobe-u.ac.jp

概要

外部知識を検索・参照して応答を生成する知識指向対話では、検索拡張生成 (Retrieval-Augmented Generation; RAG) の普及により流暢性は向上した一方、(i) ハルシネーション、(ii) 取得知識の不完全な活用、(iii) 汎用的・冗長な応答が依然として課題である。本研究では、対話穴埋め型枠組み DialFill を基盤に、複数知識スニペットからの知識選択とマスク範囲決定を統合する DialFill-Select を提案する。提案手法はデコーディング時に <GOOD>/<BAD> を導入し、候補スパンを単一パスでスコアリングすることで、アンカー (キーワード) とマスク範囲を同時に最適化して応答を生成する。OpenDialKG による評価により、既存手法と比べてノイズ耐性を高めつつ、事実整合性と情報量を維持できることを確認した。

1 はじめに

近年、外部知識を参照しながらユーザ発話に即した応答を生成する知識指向対話システムが盛んに研究されている [1, 2]。知識指向対話システムは、対話履歴に加えて外部知識を検索し、知識に基づく応答生成を行う枠組みである。近年は LLM と外部知識を統合する Retrieval-Augmented Generation (RAG) [3] の組み合わせにより流暢な応答が得られる一方、ハルシネーション、取得知識の部分的利用、汎用的で冗長な応答といった問題が残る。これらは、検索結果のどの情報を応答に反映するかが生成モデルに暗黙的に委ねられやすいことに起因する。

DialFill [4] は応答生成を「対話穴埋め」として定式化し、知識に基づいてテンプレートの一部をマスクし補完することで、知識利用の明示化と多様性の両立を目指したものである。しかし複数スニペットを扱う場合、知識選択 (どのスニペット/エンティ

ティを採るか) やマスク範囲の決定がヒューリスティックに依存しやすく、ノイズ混入や重要事実の取りこぼしが生じ得る。

本研究では、複数スニペットからの知識選択とマスク範囲決定を生成モデル内部で一貫して行う DialFill-Select を提案する。<GOOD>/<BAD> に基づく生成確率をスコアとして再利用し、アンカーとマスク範囲を単一の推論手順で同時に最適化することで、ノイズ耐性の高い応答生成を、追加分類器なしで実現することを目指す。

本稿の貢献は以下のとおりである。(1) 複数スニペットを前提とした DialFill-Select を提案し、知識選択とマスク範囲決定を統合した。(2) 単一パスのスコアリングにより推論を簡潔化した。(3) OpenDialKG の評価で有効性を示した。

2 関連研究

2.1 知識指向対話と検索拡張生成

知識指向対話システムは、対話履歴に加えて外部知識を検索・参照し、知識に基づく情報量の高い応答を生成することを目的とする。外部知識の形態は、テキスト文書に限らず、知識グラフ (Knowledge Graph; KG) やその部分グラフとして与えられる場合もある。特に KG を対象とする設定では、エンティティ同定や部分グラフ抽出に基づく知識取得の上で、応答生成を行う枠組みが議論されてきた [5, 6, 7]。

近年は、大規模言語モデル (Large Language Models; LLMs) と検索拡張生成 (Retrieval-Augmented Generation; RAG) を組み合わせた手法が広く用いられている [3]。典型的には、(i) 対話文脈から外部知識を取得し、(ii) 取得した知識を条件として応答を生成する二段構成をとる。ただしこの構成では、取得知識集合 (複数スニペット) のうち「どの知識を」「ど

の粒度で」応答に反映するかが生成過程に暗黙的に委ねられやすく、知識利用の不完全さやノイズ混入を招くことがある。

2.2 知識選択・対話穴埋め・ハルシネーション抑制

知識指向対話における重要な論点の一つは、取得した知識集合から適切な知識を選択する知識選択である。例えば Kim ら [8] は、対話履歴に沿って逐次的に知識を選択する枠組みを提案し、応答に有用な知識の抽出を目指した。また、取得知識と対話の相互作用をより明示的に扱うモデルも提案されている [9, 10]。一方で、多くの知識選択手法は「どの知識を選ぶか」に主眼が置かれ、選択された知識を応答のどの位置・どのスパンに反映するかは、条件付き生成に委ねられる場合が多い。

この点に対し、DialFill [4] は応答生成を「対話穴埋め (Dialogue Filling)」として再定式化し、取得知識に基づいて応答テンプレートの一部をマスクした上で補完することで、知識利用を明示化しつつ自然性・多様性を確保する枠組みを提示した。しかし、複数スニペットを前提とする場合、(i) どのスニペット／エンティティをアンカー (キーワード) として採用するか、(ii) どの範囲をマスクとして残すかといった決定がヒューリスティックに依存しやすく、ノイズを含む取得知識集合では重要事実の取りこぼしや不要な情報の混入が生じ得る。

また、LLM のハルシネーション抑制を目的として、対照学習等を通じて知識整合性を高める研究も報告されている [11, 12]。これらは事実整合性の観点で有効である一方、取得知識集合の中からの知識選択と、応答内での反映位置 (スパン) を同一の推論過程で同時に最適化することは必ずしも想定していない。

本研究の DialFill-Select は、複数スニペットからの知識選択 (アンカー決定) とマスク範囲の決定を、生成モデルの出力確率に基づいて統合的に行う点に特徴がある。

3 提案手法

本研究では、DialFill [4] を拡張し、複数スニペットからなる取得知識集合に対して **知識選択 (アンカー／キーワード決定)** と **マスク範囲決定** を生成モデル内部で一貫して行う対話穴埋め型知識選択モデル **DialFill-Select** を提案する。

DialFill-Select の中核は、語彙に <GOOD> と <BAD>

の2種類の制御トークンを追加し、デコーダがこれらを生成する確率をスコアとして再利用する点にある。これにより、追加の分類器やアーキテクチャ変更を導入することなく、(i) 知識スニペット／エンティティの選択、(ii) マスク範囲の選択、(iii) 対話穴埋めによる応答生成を単一の Transformer デコーダに統合できる。

具体的には、対話履歴 x と取得知識集合 $\{r_k\}$ を入力とし、(1) 取得知識内エンティティに対する **キーワードスコアリング** (Keyword Classification; KC)、(2) 応答側マスク範囲に対する **マスク範囲スコアリング** (Mask Classification; MC)、(3) **対話穴埋め** (Dialogue Filling; DF) による応答生成を、単一デコーダの条件付き言語モデリングとして学習・利用する。以下では、まず学習目的を簡潔に述べた上で、MC/KC のスコアの扱いと推論時フローを説明する。

3.1 学習目的

DialFill-Select は、DialFill [4] と同様に、対話穴埋め (DF) に対応する損失に加えて、マスク範囲スコアリング (MC) およびキーワードスコアリング (KC) の損失を組み合わせたマルチタスク学習を行う。まず、マスク付き応答テンプレート m から最終応答 y を復元する対話穴埋め損失を

$$\mathcal{L}_{DF} = - \sum_{t=1}^T \log p_{\theta}(y_t | y_{<t}, x, \{r_k\}, m) \quad (1)$$

と定義する。

一方、MC ではマスクトークン列中の各位置に対して <GOOD>/<BAD> を予測するトークン単位のクロスエントロピー損失 \mathcal{L}_{MC} を、KC ではエンティティ列中の各位置に対して <GOOD>/<BAD> を予測する損失 \mathcal{L}_{KC} をそれぞれ定義する。具体的なラベル付与手順は、後述のマスク範囲スコアリングおよびキーワードスコアリングの説明に従う。

最終的な目的関数は、これら3つの損失を重み付きで結合した

$$\mathcal{L} = \alpha_1 \mathcal{L}_{DF} + \alpha_2 \mathcal{L}_{MC} + \alpha_3 \mathcal{L}_{KC} \quad (2)$$

とし、開発セットに基づき重み $\alpha_1, \alpha_2, \alpha_3$ を決定する。なお、実験では、 \mathcal{L}_{MC} および \mathcal{L}_{KC} を順に無効化した設定 (-w/o \mathcal{L}_{MC} , -w/o \mathcal{L}_{KC}) との比較を行う。

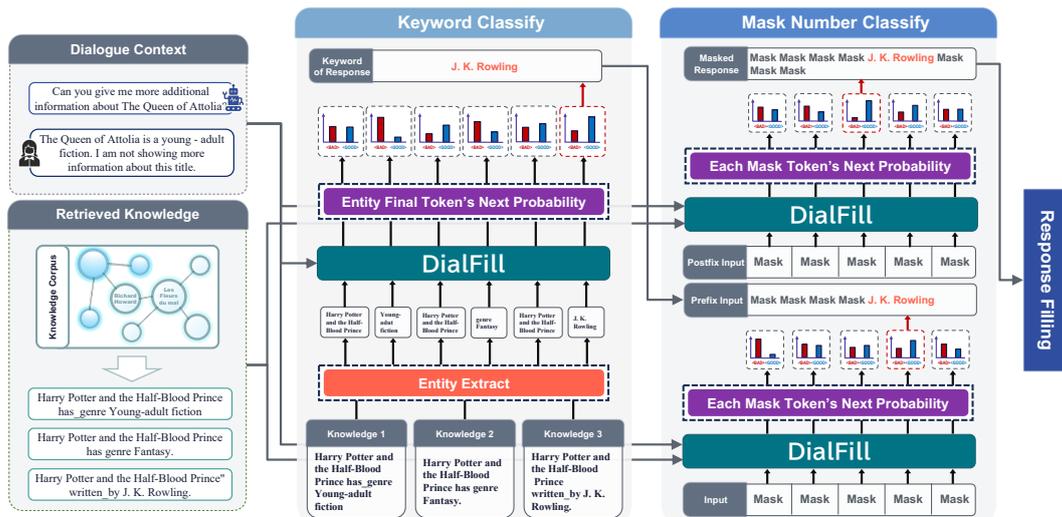


図1 DialFill-Selectにおける推論時の処理フロー。取得知識中の各エンティティを<GOOD>確率でスコアリングしてキーワード（アンカー）を選択し、左右のマスク長候補を同様に評価してマスク範囲を決定する。最後に、マスク付き応答を対話穴埋めで補完し最終応答を生成する。

3.2 マスク範囲スコアリング (Mask Classification; MC)

MCは、応答中の「どの範囲を穴埋め対象として残すか」を判定するためのスコアを定義するタスクである。教師応答 y とキーワード kw を用い、 kw 以外を [MASK] に置換した系列 m を構成する。このとき、 kw の左側・右側に連続する [MASK] の長さを候補として列挙し、各候補に対して <GOOD>/<BAD> を生成する確率を比較することで、マスク範囲の妥当性を評価する。

例えば左側マスク長 i に対して、[MASK] ^{i} の直後に制御トークンを生成させるようなシーケンスを構成し、

$$s_{MC}(i) = \log p_{\theta}(\langle \text{GOOD} \rangle | x, \{r_k\}, i) \quad (3)$$

をスコアとする。学習時には正解マスク範囲に対応する位置に <GOOD> を埋め込んだシーケンスを教師として与え、 \mathcal{L}_{MC} の一部として <GOOD> の尤度が高くなるように最適化されるため、推論時には $s_{MC}(i)$ が「そのマスク長が妥当かどうか」の指標として機能する。右側マスクについても同様に定義する。

3.3 キーワードスコアリング (Keyword Classification; KC)

KCは、複数スニペットからなる取得知識集合 $\{r_k\}$ の中から、現ターンの応答に有用なエンティティ（ひいてはスニペット）を識別するためのスコアを定義するタスクである。学習時には、各エンティティ表現の直後に <GOOD> もしくは <BAD> を挿入したシーケンスを教師として与え、実際に応答で

参照されているエンティティには <GOOD>、それ以外には <BAD> を割り当てる。これらもすべて \mathcal{L}_{KC} の中で一括して学習される。

推論時には、各エンティティ e について

$$s_{KC}(e) = \log p_{\theta}(\langle \text{GOOD} \rangle | x, \{r_k\}, e) \quad (4)$$

を有用性スコアとみなし、スコアの高いエンティティをスニペットごとのキーワード候補 kw_k として選択する。

3.4 推論時の知識選択と対話穴埋め

推論時の全体像を図1に示す。まず KC のスコア $s_{KC}(e)$ に基づき、各スニペット内のエンティティをスコアリングし、最もスコアの高いものをキーワード候補 kw_k として選択する。次に MC のスコア $s_{MC}(L_{\text{left}}), s_{MC}(L_{\text{right}})$ を用いて、左右マスク長候補 ($L_{\text{left}}, L_{\text{right}}$) ごとにスコアを計算し、スニペットとマスク長の組 ($r_k, L_{\text{left}}, L_{\text{right}}$) の中からスコアが最大となるものを選択する。

この選択結果に基づきマスク付き応答 m を構成し、最後に対話穴埋めデコーディングによりマスク部分を補完して最終応答 \hat{y} を生成する。学習・推論の両段階で同じモデル・同じ目的関数 \mathcal{L}_{DF} を用いることで、DialFill-Select は複数スニペットにまたがる知識選択とマスク範囲制御を同一の対話穴埋め枠組みに自然に統合し、ノイズを含む取得知識集合に対しても頑健な応答生成を実現する。

表 1 OpenDialKG における自動評価結果 (Test Seen / Test Unseen).

Type	Methods	Test Seen						Test Unseen					
		F1	RL	B4	MT	KF1	EF1	F1	RL	B4	MT	KF1	EF1
KB-based	DiffKG	17.5	18.0	1.2	14.8	14.2	8.1	17.9	17.8	1.2	14.8	14.1	7.2
	NPH	24.1	23.3	3.2	21.4	14.8	15.9	22.5	21.9	2.5	19.8	12.4	11.4
	GATE (Top-1)	25.1	23.9	4.2	22.1	20.5	23.5	24.3	23.2	3.7	21.6	19.2	21.1
	GATE (Top-5)	25.6	24.8	4.6	23.3	18.7	21.5	25.7	24.5	4.2	23.2	18.1	22.7
DF-based	DialFill	26.7	25.8	5.0	24.1	22.3	22.5	25.3	24.7	4.2	23.3	21.1	19.4
	DialFill-Select	27.5	26.9	5.6	27.1	23.3	27.2	26.4	26.1	4.9	26.0	22.4	25.1

表 2 DialFill-Select のアブレーション実験結果

Methods	Test Seen			Test Unseen		
	F1	B4	KF1	F1	B4	KF1
Base model	27.5	5.6	23.3	26.4	4.9	22.4
-w/o \mathcal{L}_{KC}	25.5 \downarrow _{2.0}	4.6 \downarrow _{1.0}	19.2 \downarrow _{4.1}	24.7 \downarrow _{1.7}	4.4 \downarrow _{0.5}	18.6 \downarrow _{3.8}
-w/o \mathcal{L}_{MC}	26.0 \downarrow _{1.5}	4.8 \downarrow _{0.8}	20.8 \downarrow _{2.5}	25.4 \downarrow _{1.0}	4.5 \downarrow _{0.4}	19.9 \downarrow _{2.5}
-w/o \mathcal{A}_{KC}	27.1 \downarrow _{0.4}	5.3 \downarrow _{0.3}	21.2 \downarrow _{2.1}	26.1 \downarrow _{0.3}	4.7 \downarrow _{0.2}	20.2 \downarrow _{2.2}
-w/o \mathcal{A}_{MC}	26.7 \downarrow _{0.8}	5.2 \downarrow _{0.4}	23.3 \downarrow _{0.0}	25.7 \downarrow _{0.7}	4.4 \downarrow _{0.5}	22.1 \downarrow _{0.3}

4 実験

本研究では、知識グラフに基づく知識指向対話ベンチマークである OpenDialKG [6] を用いて、提案手法 DialFill-Select の有効性を評価する。評価は OpenDialKG テストセットで行う。データ前処理および取得知識の構成は DialFill [4] に準拠した。

評価指標には、応答品質の指標として F1, ROUGE-L (RL), BLEU-4 (B4), METEOR (MT) を用い、知識との整合性を測る指標として Knowledge-F1 (KF1) および Entity-F1 (EF1) を用いる。生成モデルには GPT-2 Small を採用した。ハイパーパラメータは DialFill [4] に従う。比較手法として、KB ベース手法である DiffKG [7], NPH [12], GATE [9], および DialFill [4] を用いる。

4.1 全体結果

表 1 に OpenDialKG における自動評価結果を示す。KB ベース手法の中では GATE (Top-5) が相対的に高い F1・B4 を達成している一方、KF1・EF1 は十分に伸びておらず、ノイズを含む取得知識に対する知識利用の難しさが示唆される。DialFill は GATE と比べて F1・B4 と KF1 を改善しており、対話穴埋めによる知識利用の明示化が有効であることが確認できる。

提案手法 DialFill-Select は、*Test Seen / Test Unseen* の両設定で、F1・B4・KF1・EF1 を含む主要指標にお

いて DialFill を一貫して上回る。とくに KF1 は *Test Seen* で 23.3, *Test Unseen* で 22.4 と改善しており、複数スニペットからの知識選択とマスク範囲制御を統合的に最適化することが、情報量と事実整合性の両立に寄与することが分かる。

4.2 アブレーション

DialFill-Select を構成する要素の寄与を分析するため、OpenDialKG において損失項および推論手順順に無効化したアブレーション実験を行った (表 2)。まず、キーワード分類損失 \mathcal{L}_{KC} を除去すると KF1 が大きく低下し、学習段階で有用なエンティティ/スニペットを識別することが知識整合性の向上に不可欠であることが示される。同様に、マスク分類損失 \mathcal{L}_{MC} を除去した場合も KF1 が一貫して低下しており、マスク範囲の学習が「どの知識をどの位置で反映するか」に直接影響することが分かる。

一方、推論時の KC 手順 \mathcal{A}_{KC} または MC 手順 \mathcal{A}_{MC} を無効化した場合、性能低下は損失項の除去に比べて小さいものの、F1・B4・KF1 はいずれもフル構成 (Base model) を下回る。学習で獲得したスコアを用いてスニペット選択とマスク長探索を行う推論手順が、ノイズを含む取得知識集合に対して安定した性能を得る上で有効であることを示唆する。

5 まとめ

本稿では、対話穴埋め枠組み DialFill を拡張し、知識選択とマスク範囲制御を生成モデル内部で統合的に行う DialFill-Select を提案した。提案手法は、デコーダの <GOOD>/<BAD> 生成確率を用いてアンカーエンティティとマスク範囲を単一パスでスコアリングし、追加の分類器を用いることなくノイズを含む取得知識に対して頑健な応答生成を実現する。OpenDialKG における実験の結果、DialFill-Select は既存の KB ベース手法および DialFill を事実整合性と情報量の両面で一貫して上回ることを確認した。

謝辞

本研究の一部は、JST A-STEP JPMJTR24RG, JSPS 科研費 JP25K00838 の支援を受けたものである。

参考文献

- [1] Marjan Ghazvininejad, Chris Brockett, Ming-Wei Chang, William B. Dolan, Jianfeng Gao, Wen-tau Yih, and Michel Galley. A knowledge-grounded neural conversation model. In **Proceedings of the AAAI Conference on Artificial Intelligence**, 2018.
- [2] Emily Dinan, Stephen Roller, Kurt Shuster, Angela Fan, Michael Auli, and Jason Weston. Wizard of wikipedia: Knowledge-powered conversational agents. In **Proceedings of the International Conference on Learning Representations (ICLR)**, 2019.
- [3] Patrick Lewis, Ethan Perez, Aleksandra Piktus, Fabio Petroni, Vladimir Karpukhin, Naman Goyal, Heinrich Küttler, Mike Lewis, Wen-tau Yih, Tim Rocktäschel, Sebastian Riedel, and Douwe Kiela. Retrieval-augmented generation for knowledge-intensive NLP tasks. In **Advances in Neural Information Processing Systems (NeurIPS)**, 2020.
- [4] Qiang Xue, Tetsuya Takiguchi, and Yasuo Ariki. Dialfill: Utilizing dialogue filling to integrate retrieved knowledge in responses. **IEEE Access**, Vol. 13, pp. 61123–61135, 2025.
- [5] Xueliang Zhao, Wei Wu, Can Xu, Chongyang Tao, Dongyan Zhao, and Rui Yan. Knowledge-grounded dialogue generation with pre-trained language models. In **Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP)**, pp. 3377–3390, Online, 2020. Association for Computational Linguistics.
- [6] Seungwhan Moon, Pararth Shah, Anuj Kumar, and Rajen Subba. Opendialkg: Explainable conversational reasoning with attention-based walks over knowledge graphs. In **Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics**. Association for Computational Linguistics, 2019.
- [7] Yi-Lin Tuan, Sajjad Beygi, Maryam Fazel-Zarandi, Qiaozi Gao, Alessandra Cervone, and William Yang Wang. Towards large-scale interpretable knowledge graph reasoning for dialogue systems. In **Findings of the Association for Computational Linguistics: ACL 2022**, pp. 383–395, 2022.
- [8] Byeongchang Kim, Jaewoo Ahn, and Gunhee Kim. Sequential latent knowledge selection for knowledge-grounded dialogue. In **International Conference on Learning Representations (ICLR)**, 2020.
- [9] Lang Qin, Zhongtian Bao, Hongru Liang, Yao Zhang, et al. Well begun is half done: Generator-agnostic knowledge pre-selection for knowledge-grounded dialogue. In **Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing (EMNLP)**, 2023.
- [10] Jiaqi Bai, Ze Yang, Jian Yang, Hongcheng Guo, and Zhoujun Li. KINet: Incorporating relevant facts into knowledge-grounded dialog generation. **IEEE/ACM Transactions on Audio, Speech, and Language Processing**, Vol. 31, pp. 1213–1222, 2023.
- [11] Weiwei Sun, Zhengliang Shi, Shen Gao, Pengjie Ren, Maarten de Rijke, and Zhaochun Ren. Contrastive learning reduces hallucination in conversations. In **Proceedings of the AAAI Conference on Artificial Intelligence**, pp. 13618–13626, 2023.
- [12] Nouha Dziri, Ehsan Kamalloo, Kory W. Mathewson, and Osmar R. Zaiane. Neural path hunter: Reducing hallucination in dialogue systems via path grounding. In **Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing (EMNLP)**, 2021.