

指示文書による検索意図の変化を考慮した 指示追従検索モデルの学習

勝又 智¹ 杉山 誠治²

¹ 株式会社レトリバ ² 愛媛大学大学院理工学研究科

satoru.katsumata@retrieva.jp sugiyama@ai.cs.ehime-u.ac.jp

概要

情報検索分野では、クエリに加えて指示文書を考慮する指示追従検索が注目されている。本タスクでは、クエリと文書のみでは関連していても、指示内容を踏まえると適合しない事例が存在するため、指示内容を明示的に考慮した学習が求められる。本研究では、指示文書が検索結果に与える影響に基づいて対照学習の重みを動的に調整する手法を提案する。実験の結果、提案手法は通常の対照学習と比べ、複数のベースモデルにおいて指示追従検索性能を一貫して向上させることを確認した。

1 はじめに

情報検索の分野では、テキスト埋め込みモデルの性能向上に伴い、既存の意味検索を発展させた指示追従検索と呼ばれる応用研究が行われている。意味検索では、与えられたクエリとそれに対応する関連文書について表層的な類似度だけでなく、意味的な類似度を踏まえた検索が行われる。一方で、指示追従検索では、クエリの他に指示文書が与えられ、クエリと指示文書を踏まえた意味検索を行う必要がある。例として、InfoSearch [1] では、クエリの他に関連文書として望ましい文書フォーマットの指示などの様々な指示内容が与えられ、クエリの他に指示内容を踏まえた検索結果を返す必要がある (図 1)。

指示追従検索に焦点を当てた研究の多くは、学習・評価データの作成に関する取り組みを行っている。既存研究 [1, 2, 3, 4, 5] では、大規模言語モデルを用いて指示文書を自動生成する手法が提案されており、多様かつ現実的な指示文書の作成を目的としている。このようなデータ作成のアプローチは、指示追従検索モデルの性能向上に有効である一方で、新たな分野に適用する際には、負例データを含む学習データをあらかじめ作成する必要がある、データ

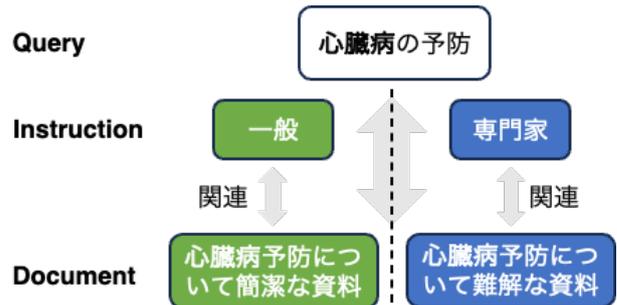


図1 指示追従検索の概要図。指示文書によって関連文書が絞り込まれている。

構築のコストが高くなるという課題がある。このような背景を踏まえ、本研究では指示追従検索モデルの改善に向けて、学習データではなく、学習時の目的関数の改善に取り組む。

本研究では、指示追従検索は通常の情報検索と比べて、詳細な関連性判断が求められるという直感に基づき、対照学習の改善を行う。指示追従検索で扱われるデータでは、クエリと文書の関係のみを考慮すると関連している文書であっても、指示文書の内容を踏まえると関連しない状況が想定される。そのため、指示追従検索モデルには、クエリに加えて指示内容を考慮した関連性判断が求められる。本研究では、このような粒度の違いに起因する課題に対して、指示内容を明示的に考慮した目的関数を提案する。具体的には、指示文書の内容が検索結果に与える影響を Instruction Gain (IG) と定義し、この値を対照学習における損失関数の重みとして用いる。IG が大きい事例ほど、指示内容が検索結果に強く影響していると考えられるため、提案手法では、そのような事例の教師信号がより強くモデルに反映されるようにする。また、機械学習全般として、学習初期は簡単な事例を取り扱い、学習が進むにつれて困難な事例を扱うこと (Curriculum Learning [6], Self-Paced Learning [7]) が効果的であることが報告されている。本研究では事例の難易度を「どれだけ

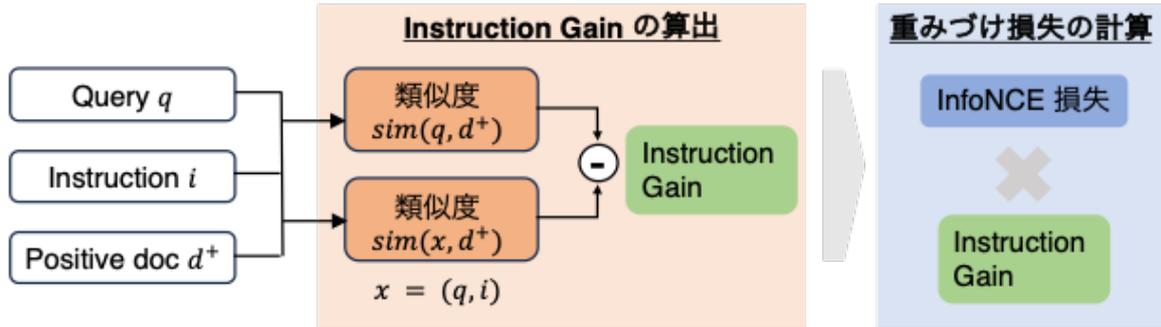


図2 提案手法の概要図.

指示内容を考慮するか」と定義し、学習初期は指示内容の影響を小さくし、学習が進むにつれて大きくしていく Self-Paced Learning (SPL) を導入する。

IG に基づく重みづけを導入した学習手法が、指示追従検索モデルとして有効であるかを検証するため、既存の評価ベンチマークを用いた実験を行った。また、SPL の導入による効果についても同様に検証した。その結果、提案手法は複数のベースモデルに対して性能を向上させ、指示追従検索における有効性を確認した。

2 提案手法

本研究の提案手法は、指示文書が検索結果に与える影響を Instruction Gain (IG) として定量化し、この値に基づいて対照学習の損失関数を重みづけすることで、指示追従検索における細粒度な関連性判断を明示的に学習することを目的としている。提案手法の概要図を図2に示す。

InfoNCE 本研究では、学習データとしてクエリ q と指示文書 i 、クエリと指示文書を結合した入力テキスト $x = (q, i)$ を用意する。また、この入力に関連した正例文書 d^+ と負例文書 d^- も用いて学習を行う。埋め込みモデルの学習では InfoNCE [10, 11] と呼ばれる損失関数を用いることが多い。

$$L_{\text{InfoNCE}} = -\frac{1}{N} \sum_{j=1}^N \log \frac{\exp(\text{sim}(x_j, d_j^+)/\tau)}{\sum_{y \in B(j)} \exp(\text{sim}(x_j, y)/\tau)} \quad (1)$$

なお、 N はバッチサイズを表しており、式1では in-batch negative と呼ばれる、バッチ中の他の正例文書も負例として使用するため、 $B(j)$ は以下のように定義される：

$$B(j) = \{d_k^+, d_k^- \mid 1 \leq k \leq N\} \quad (2)$$

また、 τ は温度パラメータであり、 $\text{sim}(\cdot, \cdot)$ は類似度を計測する関数である。

Instruction Gain による重みづけ 本研究では、指示文書が検索結果に与える影響を定量化するための指標 IG を導入する。IG は、クエリと正例文書の類似度と、クエリと指示文書を結合した表現と正例文書間の類似度の差分として定義される。

$$IG_j = \text{sim}(x_j, d_j^+) - \text{sim}(q_j, d_j^+) \quad (3)$$

本研究では式3で導入した IG をもとに、目的関数 InfoNCE (式1) の重みづけを行う。

$$L_{\text{InfoNCE+IG}} = -\frac{1}{N} \sum_{j=1}^N w_j \log \frac{\exp(\text{sim}(x_j, d_j^+)/\tau)}{\sum_{y \in B(j)} \exp(\text{sim}(x_j, y)/\tau)} \quad (4)$$

$$\tilde{w}_j = \text{softplus}\left(\frac{IG_j}{\alpha}\right), w_j = \frac{\tilde{w}_j}{\frac{1}{N} \sum_{l=1}^N \tilde{w}_l}$$

IG に基づく重みづけでは、温度パラメータ α によってスケールを行った後、活性化関数 $\text{softplus}(\cdot)$ を適用する。 $\text{softplus}(\cdot)$ を用いることで、IG に基づく重みは非負かつ滑らかに写像され、小さな値に対して過度な強調が生じない一方で、大きな値は相対的に強調される。さらに、ミニバッチ内で重みの平均が1となるよう正規化することで重み w_j を算出し、これを InfoNCE の重みとして用いることで、重みに起因する損失スケールの変動を抑制する。以上の処理により、指示内容の影響が大きい事例ほど教師信号が強く反映される。

機械学習分野では、学習初期は簡単な事例を取り扱い、学習が進むにつれて困難な事例を扱うことで性能が向上することが報告されている。そこで本研究では、この難易度として「どれだけ指示内容を考慮するか」と見なして、IG の温度パラメータ α について、学習が進むにつれて値を小さくする Self-Paced Learning (SPL) [7] を導入する。学習初期の値 α_s と学習終了時の値 α_e をハイパーパラメータとして設定し、学習ステップ t に対して線形に α_t を更新していく。式4の $\text{softplus}(\cdot)$ と本操作を組み

表 1 指示追従検索の実験結果. Average Score は各検索指標の平均値を示す. 太字は各列の中で最も高い数値を示し, 下線は Qwen3-Embedding-4B がベースモデルの中で最も高い数値を示す.

	Robust04		News21		Core17		Average	
	MAP	p-MRR	nDCG	p-MRR	MAP	p-MRR	Score	p-MRR
Qwen3-Embedding-4B	<u>26.3</u>	+3.7	24.9	+1.2	21.1	+7.1	<u>24.1</u>	+4.0
w/ InfoNCE	22.1	+8.8	27.4	+4.0	21.2	+12.5	23.6	+8.4
w/ InfoNCE+IG (Ours)	22.4	+9.7	26.6	+2.0	21.6	+12.1	23.5	+7.9
w/ InfoNCE+IG+SPL (Ours)	21.4	+11.3	27.2	+3.9	21.5	+14.5	23.4	+9.9
BM25 [8]	12.1	-3.1	19.3	-2.1	8.1	-1.0	13.2	-2.1
Focal-InfoNCE [9]	20.0	+6.9	23.3	+2.4	19.8	+10.1	21.0	+6.5
Promptriever-7B [5]	27.6	+6.6	24.9	+1.7	20.5	+11.4	24.3	+6.6

合わせることで, 学習初期は指示内容を考慮しない通常の対照学習を行い, 学習が進むにつれて指示内容が教師信号に影響するようになる.

3 実験

本研究で提案した Instruction Gain (IG) による重みづけ学習と Self-Paced Learning (SPL) による動的な重みの調整が, 指示追従検索モデルとして有効であるか検証を行った. 具体的には, 通常の対照学習 InfoNCE を用いた場合と比較して, 提案手法で学習したモデルの性能が向上しているか確認した.

3.1 実験設定

本研究では, ベースモデルに対して Weller ら [5] が作成した指示追従検索学習データ¹⁾を用いて学習を行った. このデータはあるクエリに対して, 指示文書と正例文書, 負例文書がアノテーションされている. また, ベースモデルには Qwen3-Embedding-4B²⁾を用いた場合と, Qwen3-4B-Base³⁾を用いた場合で検証を実施し, テキスト埋め込み向けの学習が行われているモデルへの提案手法の効果を調査した. 式 1 や式 4 の類似度関数にはコサイン類似度を用い, 式 3 の類似度関数には一般的な検索性能の観点から, 既存のリランキングモデル⁴⁾を用いた. 詳細なハイパーパラメータについては §B に記載している.

評価ベンチマークとして, 本研究は Weller ら [2] が提案したものをを用いた. このベンチマークは評価尺度として, 従来の検索評価指標 (MAP, nDCG) の他に指示追従検索性能を評価する p-MRR を提案して

おり, 本研究でも同様の指標を用いた. これらの評価尺度は値が大きい方が優れていることを示し, 特に p-MRR は-100 から 100 の値を取る. 従来の検索評価指標は 0 から 100 の値を取る. このベンチマークは 3 種のサブセット (Robust04/News21/Core17) から構成されており, それぞれ関連文書の数や指示文書の長さが異なる⁵⁾. その違いの一つとして, Robust04 は他 2 つのサブセットと比較して, 指示文書の単語数が多いことが挙げられる.

比較として, 表層一致による検索を行う BM25 [8] のスコアを記載する. また, 通常の情報検索タスクに焦点を当て, InfoNCE に対して重みづけを行った手法である Focal-InfoNCE [9] を用いた場合も評価した. 本研究で使用した学習データを公開した Weller ら [5] は, 当該学習データを用いて訓練したモデル Promptriever-7B⁶⁾も併せて公開している. 本研究では, この公開モデルも評価を行った.

3.2 実験結果

表 1, 表 2 にベースモデルとして Qwen3-Embedding-4B を使用した場合と, Qwen3-4B-Base を使用した場合の実験結果を示す.

Qwen3-Embedding-4B 表 1 の p-MRR が各モデルの指示追従検索性能を示している. この結果から, InfoNCE に対して IG の値を重みづけするのみだと Robust04 ではある程度の向上が確認されたが, 他 2 種のサブセットでは有効ではないことがわかる. 一方で, IG の重みについて, SPL を利用することで Robust04 や Core17 について InfoNCE より指示追従検索性能が向上していることが観察さ

1) 学習データの詳細は §A に記載する.

2) <https://huggingface.co/Qwen/Qwen3-Embedding-4B>

3) <https://huggingface.co/Qwen/Qwen3-4B-Base>

4) <https://huggingface.co/BAAI/bge-reranker-v2-m3>

5) 各サブセットの詳細な情報は §C に記載している.

6) <https://huggingface.co/samaya-ai/promptriever-llama2-7b-v1>

表 2 Qwen3-4B-Base に対して学習したモデルの実験結果. 数値は各サブセットの平均値を示している.

	Score	p-MRR
w/ InfoNCE	22.1	+5.4
w/ InfoNCE+IG (Ours)	22.1	+5.4
w/ InfoNCE+IG+SPL (Ours)	22.4	+6.6

れる. その結果として, 各サブセットの平均値でも通常の InfoNCE より 1.5 ポイント向上していることを確認した. また, 表層一致を利用した検索方式である BM25, 目的関数への重みづけ手法である Focal-InfoNCE, 同様の学習データを使用した Promptriever-7B と比べても提案手法で学習されたモデルは指示追従検索において高い性能を達成した.

一般的な検索性能として, MAP や nDCG の結果から, 提案手法はあまり影響がないことが示唆される. 特に平均スコアから, 通常の InfoNCE と提案手法 2 種は同程度の性能となった.

Qwen3-4B-Base 表 2 から, Qwen3-Embedding-4B と同様に IG の重みづけのみだと通常の InfoNCE と同程度の性能となった. 一方で, SPL を組み合わせることにより, 特に指示追従検索性能に関して+1.2 ポイントの向上が確認された. この結果と Qwen3-Embedding-4B の結果から, 提案手法はベースモデルがテキスト埋め込み向けの学習が行われているかどうかに関わらず有効であると考えられる.

4 議論

表 1, 2 の結果から, 提案手法の中でも, SPL を用いることにより指示追従検索性能が向上していることが確認された. この性能向上の要因を分析するため, SPL の適用時における重み w_j の変化を確認する. 学習データ 10K に対する重み w_j のヒストグラムを図 3 に示す. この図から, 温度パラメータが大きい学習初期 ($\alpha_t = 4.0$) では, 重み w_j が 1.0 付近に集中していることが観察される. 学習が進み, 温度パラメータ α_t が小さくなるにつれて分布は徐々に広がり, 学習終盤 ($\alpha_t = 0.5$) では多くの事例は 0 近辺の小さい重みとなる一方で, 一部の事例が大きい重みとなっていくことが確認される. これらの結果から, 学習初期には通常の InfoNCE に近い学習が行われ, 学習の進行に伴って指示内容の影響が大きい事例が強調されるようになることが示唆される. このような重み分布の変化により, SPL が指示追従検索において効果的に機能していると考えられる.

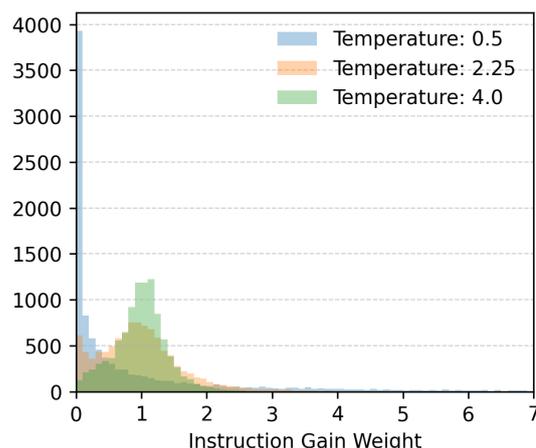


図 3 Self-Paced Learning に関する重み w_j のヒストグラム. 0.1 ごとに作成.

表 1 の Robust04 を確認すると, 通常の InfoNCE と比べ, SPL を用いて IG による重みづけを行った場合, p-MRR は +2.5 ポイント向上しており, 次点で Core17 が +2.0 ポイントの向上となっている. この要因として, 指示内容の詳細さが影響していると考えられる. 各サブセットについて, 指示文書の単語数が最も多いのは Robust04, 次点が Core17, News21 が最も少ない. このことから, Robust04 は特に長文を解釈して指示内容を反映させた指示追従検索を行う必要があり, 学習したモデルはこの点において効果的に機能していると考えられる. 一方で, News21 では改善が確認されず, 指示文書が短い設定では提案手法の効果が相対的に小さいことが示唆される.

各種実験結果より, 提案手法の一般的な検索性能は, InfoNCE を用いた場合と同程度であることが確認された. これは, 提案手法が重みづけにおいて指示文書内容の反映に重点を置いており, 一般的な検索内容を明示的には考慮していないためであると考えられる.

5 おわりに

本研究では, 指示追従検索において, 指示文書を重みとした対照学習を用いる手法を提案した. また, 学習が進むにつれて重みを調整する手法も提案した. これらの手法について検証を行い, 指示追従検索性能について, 通常の対照学習と比較して 1.5 ポイントの向上を確認した. 提案手法の指示文書を考慮する手法として, リランキングモデルを用いているため, 通常の対照学習と比べて計算コストが大きいことが課題である. 今後は指示内容を考慮する手法としてより軽量な手法を検討したい.

謝辞

本研究は九州大学情報基盤研究開発センター研究用計算機システムの民間利用を利用したものです。

参考文献

- [1] Jianqun Zhou, Yuanlei Zheng, Wei Chen, Qianqian Zheng, Shang Zeyuan, Wei Zhang, Rui Meng, and Xiaoyu Shen. Beyond content relevance: Evaluating instruction following in retrieval models. In **Proceedings of The Thirteenth International Conference on Learning Representations**, 2025.
- [2] Orion Weller, Benjamin Chang, Sean MacAvaney, Kyle Lo, Arman Cohan, Benjamin Van Durme, Dawn Lawrie, and Luca Soldaini. FollowIR: Evaluating and teaching information retrieval models to follow instructions. In **Proceedings of the 2025 Conference of the Nations of the Americas Chapter of the Association for Computational Linguistics: Human Language Technologies (Volume 1: Long Papers)**, pp. 11926–11942, 2025.
- [3] Hanseok Oh, Hyunji Lee, Seonghyeon Ye, Haebin Shin, Hansol Jang, Changwook Jun, and Minjoon Seo. INSTRUCTIR: A benchmark for instruction following of information retrieval models. arXiv preprint arXiv:2402.14334, 2024.
- [4] Tingyu Song, Guo Gan, Mingsheng Shang, and Yilun Zhao. IFIR: A comprehensive benchmark for evaluating instruction-following in expert-domain information retrieval. In **Proceedings of the 2025 Conference of the Nations of the Americas Chapter of the Association for Computational Linguistics: Human Language Technologies (Volume 1: Long Papers)**, 2025.
- [5] Orion Weller, Benjamin Van Durme, Dawn Lawrie, Ashwin Paranjape, Yuhao Zhang, and Jack Hessel. Promptriever: Instruction-trained retrievers can be prompted like language models. In **Processings of The Thirteenth International Conference on Learning Representations**, 2025.
- [6] Yoshua Bengio, Jérôme Louradour, Ronan Collobert, and Jason Weston. Curriculum learning. In **Proceedings of the 26th Annual International Conference on Machine Learning**, 2009.
- [7] M. Pawan Kumar, Benjamin Packer, and Daphne Koller. Self-paced learning for latent variable models. In **Proceedings of the 24th International Conference on Neural Information Processing Systems - Volume 1**, 2010.
- [8] Stephen Robertson and Hugo Zaragoza. The probabilistic relevance framework: BM25 and beyond. **Foundations and Trends in Information Retrieval**, Vol. 3, No. 4, p. 333–389, 2009.
- [9] Pengyue Hou and Xingyu Li. Improving contrastive learning of sentence embeddings with focal InfoNCE. In **Findings of the Association for Computational Linguistics: Empirical Methods in Natural Language Processing (EMNLP) 2023**, 2023.
- [10] Aaron van den Oord, Yazhe Li, and Oriol Vinyals. Representation learning with contrastive predictive coding. arXiv preprint arXiv:1807.03748, 2019.
- [11] Vladimir Karpukhin, Barlas Oguz, Sewon Min, Patrick Lewis, Ledell Wu, Sergey Edunov, Danqi Chen, and Wentaoh Yih. Dense passage retrieval for open-domain question answering. In **Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP)**, 2020.

A 学習データ

本研究では学習データとして、Weller ら [5] が公開している指示追従検索学習データ⁷⁾ を用いた。本データはクエリと指示文書、正例文書と負例文書がアノテーションされている。本研究で利用した学習データの件数は 440,402 である。

B ハイパーパラメータ

InfoNCE, InfoNCE+IG, InfoNCE+IG+self-paced, Focal-InfoNCE の学習に使用したハイパーパラメータを表 3 に示す。なお、 α_s と α_e については、学習データの一部を開発データとして分割したデータを用いて損失関数の値を求め、この値を用いて探索を行った。

表 3 学習に関するハイパーパラメータ。

	InfoNCE	InfoNCE+IG	InfoNCE+IG+Self-Paced	Focal-InfoNCE
Training Parameter			LoRA	
LoRA Rank/Alpha			64/128	
Training Epoch			1	
Batch Size			16	
Gradient Accumulation			2	
Learning Rate			5e-5	
Max Length			512	
InfoNCE Temperature τ			0.05	
IG Temperature α				
Qwen3-Embedding-4B		1.0	$\alpha_s: 4.0, \alpha_e: 0.5$	-
Qwen3-4B-Base			$\alpha_s: 4.0, \alpha_e: 0.25$	

C FollowIR ベンチマーク

本研究では評価ベンチマークとして Weller ら [2] が提案した FollowIR ベンチマークを用いた。評価の実装は mteb⁸⁾ v1.38.33 を用いた。なお、評価尺度は Weller らが用いたものを使用しており、検索評価指標として Robust04 と Core17 では MAP@1000 を、News21 では nDCG@5 を用いた。指示追従検索性能の評価には p-MRR を用いた。表 4 に FollowIR の各サブセットのクエリ件数、指示文書の単語数、クエリに対する関連文書数を記載する。

表 4 FollowIR の統計情報。

サブセット	クエリ件数	指示文書の単語数	クエリに対する関連文書数
Robust04	52	75.2	19.8
News21	32	46.9	19.2
Core17	20	53.5	32.7

7) <https://huggingface.co/datasets/samaya-ai/msmarco-w-instructions>

8) <https://github.com/embeddings-benchmark/mteb>