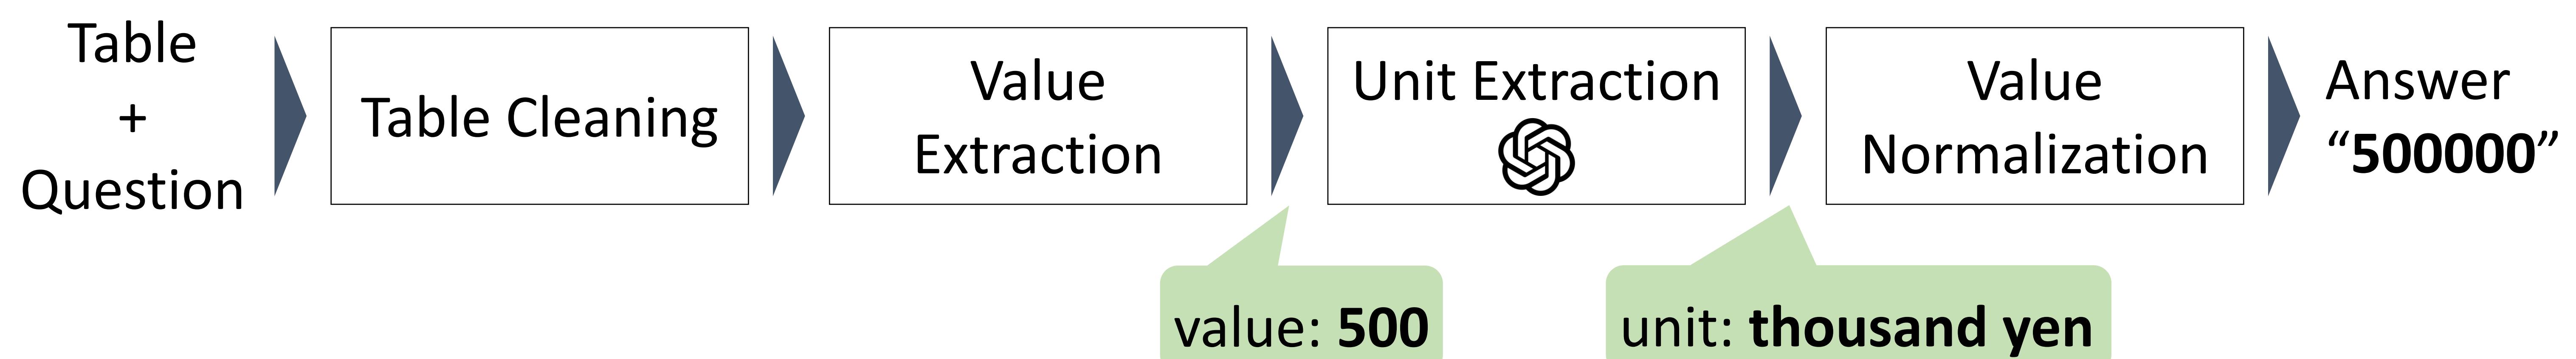


Koji Tanaka, Daiki Shirafuji and Tatsuhiko Saito

Proposed Pipeline



Value Extraction

Q: 株式会社大和証券グループ本社の2018年における「潜在株式調整後 1 株当たり当期純利益、経営指標等」は？

回次	第79期	第80期	第81期	score
決算年月	2016年3月	2017年3月	2018年3月	0.8
1 株当たり当期純利益 (円)	68.25	61.53	66.88	0.6
潜在株式調整後 1 株当たり当期純利益 (円)	67.68	61.14	66.45	0.4
自己資本比率 (%)	6.0	6.3	6.0	0.2
				0

回次	第79期	第80期	第81期
決算年月	2016年3月	2017年3月	2018年3月
1 株当たり当期純利益 (円)	68.25	61.53	66.88
潜在株式調整後 1 株当たり当期純利益 (円)	67.68	61.14	66.45
自己資本比率 (%)	6.0	6.3	6.0

回次	第79期	第80期	第81期
決算年月	2016年3月	2017年3月	2018年3月
1 株当たり当期純利益 (円)	68.25	61.53	66.88
潜在株式調整後 1 株当たり当期純利益 (円)	67.68	61.14	66.45
自己資本比率 (%)	6.0	6.3	6.0

1. Computing similarities between a given question and individual cells by retrievals: the vector search with BERT-base, the TF-IDF approach, and the hybrid method.
2. Identifying the top-scoring cell ($c^{(1)}$), then retrieving the second-best ($c^{(2)}$) from cells outside the row and column of $c^{(1)}$.
3. Extracting the value from the cell located at the intersection of $c^{(1)}$ and $c^{(2)}$.

Dataset Construction for Contrastive Learning of Language Models

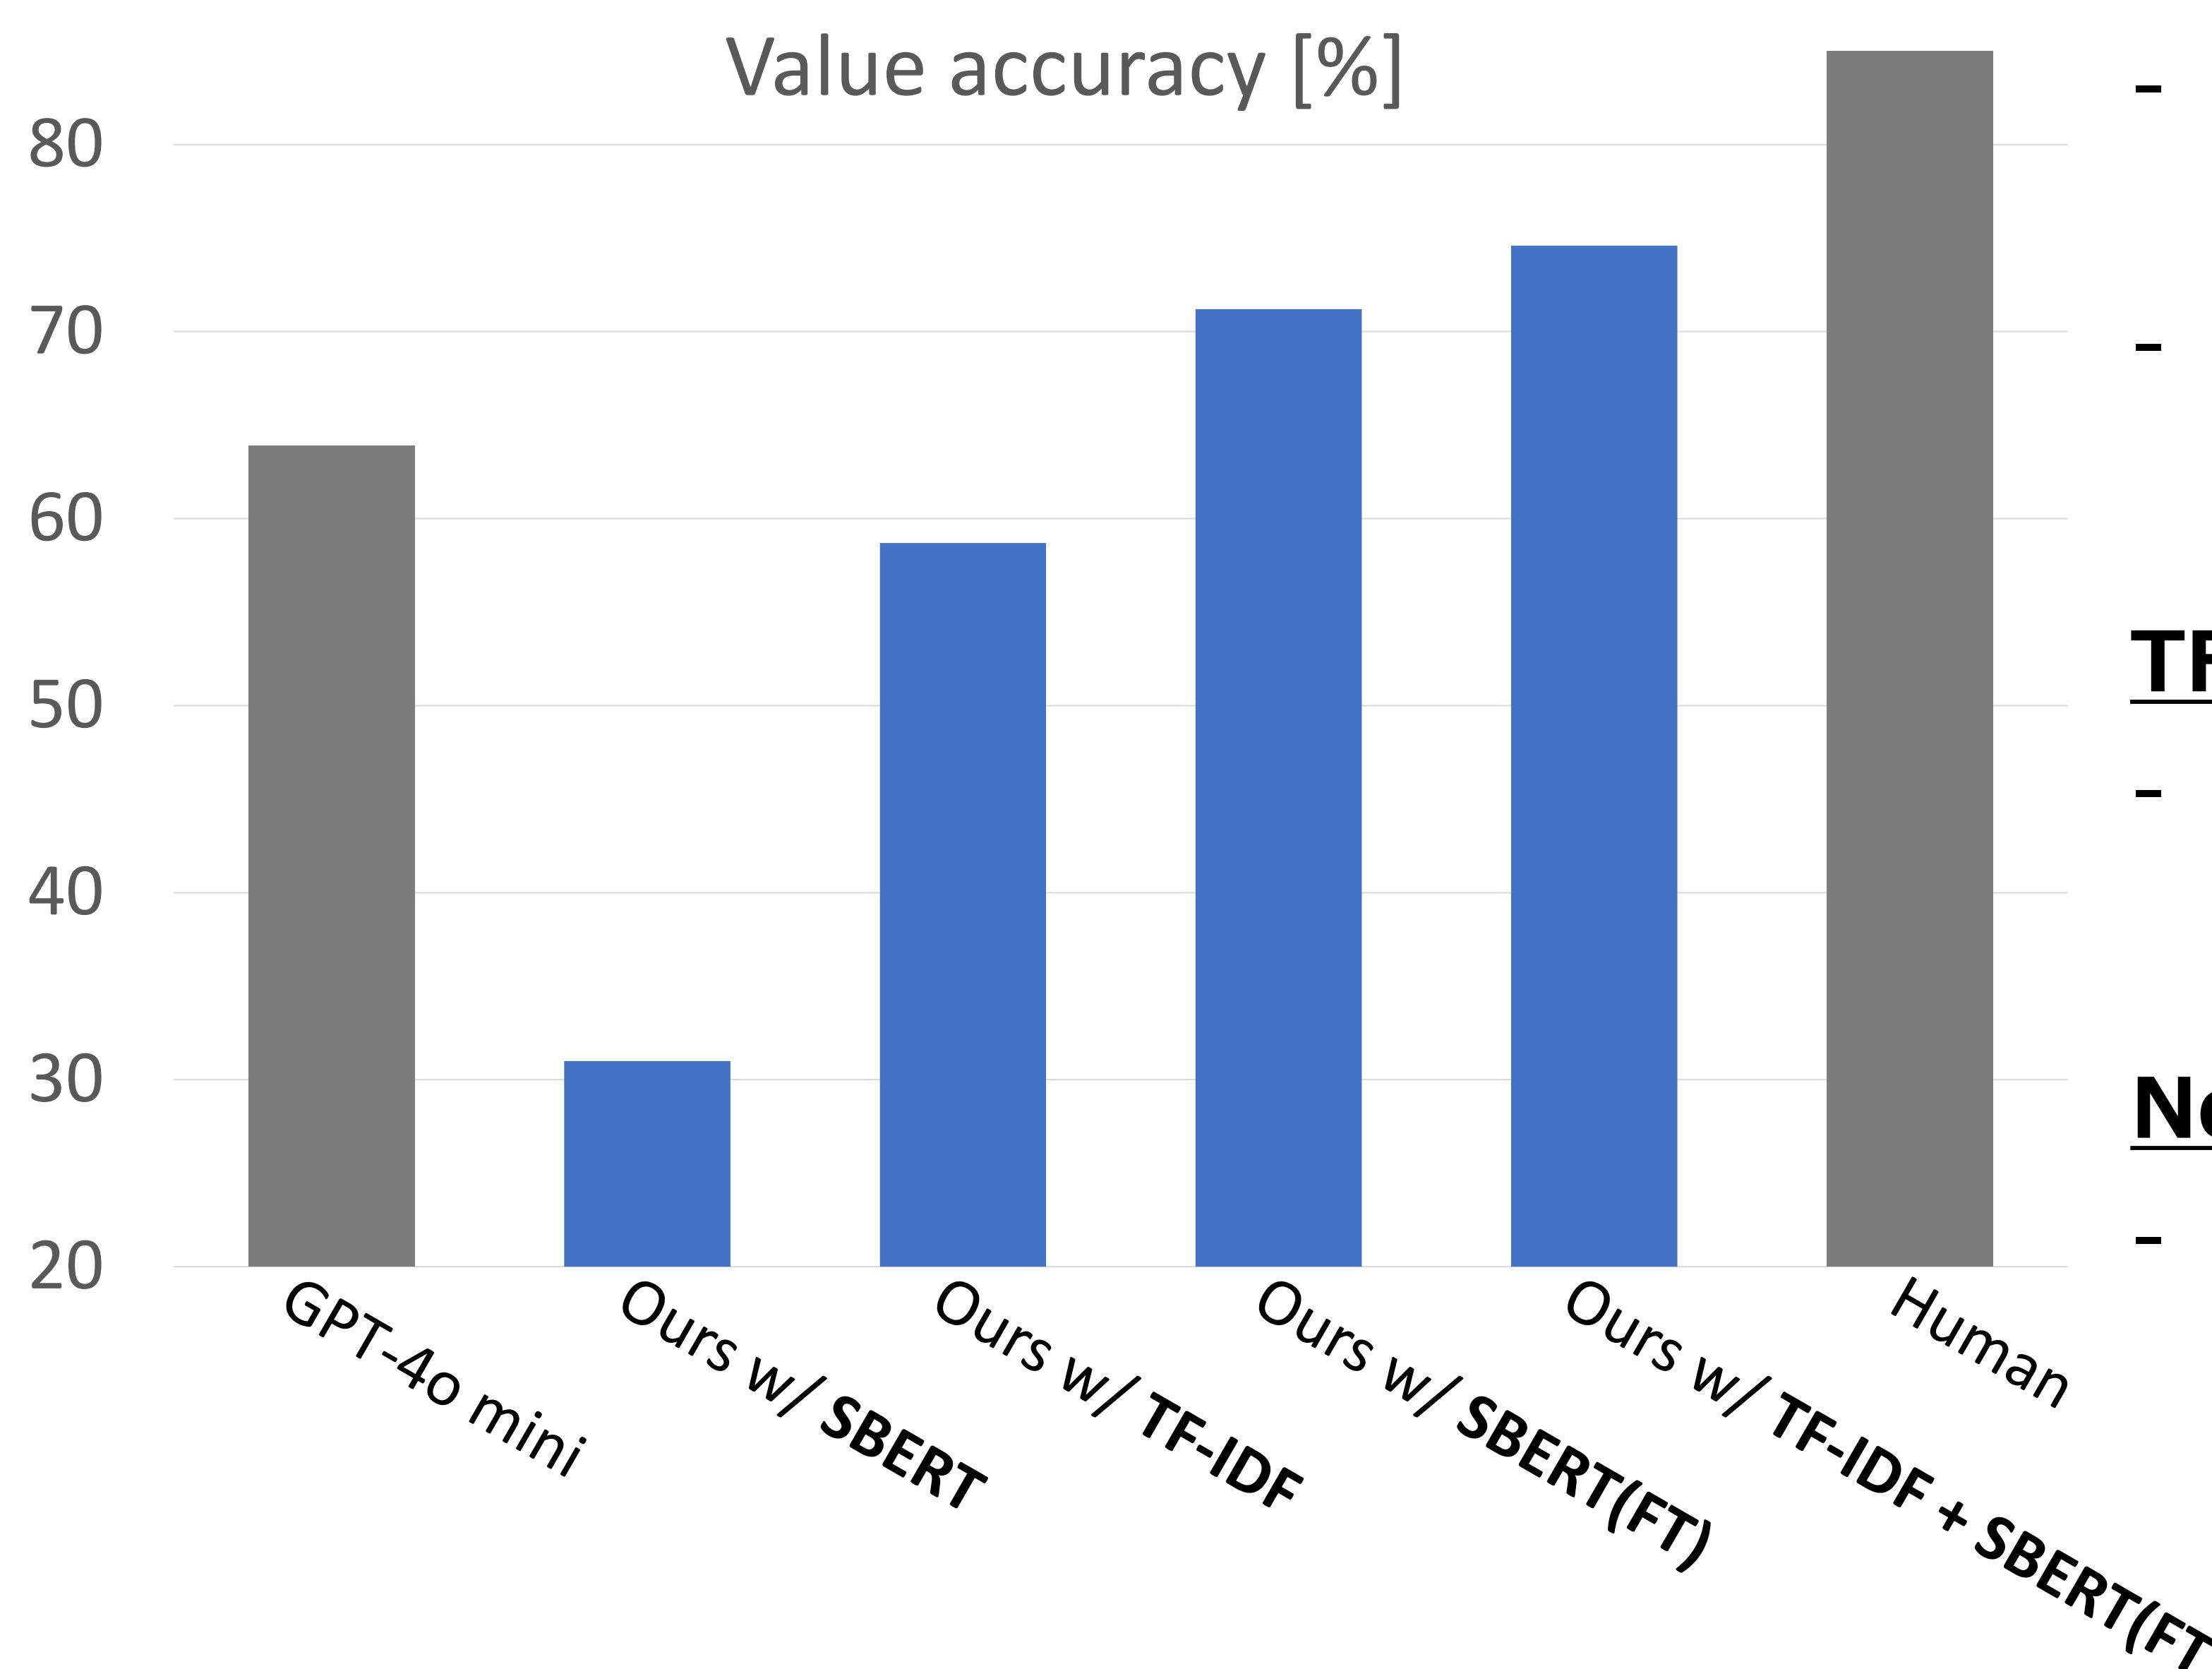
回次	第79期	第80期	第81期	$s_1 = \text{"回次 第79期 第80期 第81期"}$
決算年月	2016年3月	2017年3月	2018年3月	$s_2 = \text{"決算年月 2016年3月 2017年3月 2018年3月"}$
1 株当たり当期純利益 (円)	68.25	61.53	66.88	$s_3 = \text{"1 株当たり当期純利益 (円)"}$
潜在株式調整後 1 株当たり当期純利益 (円)	67.68	61.14	66.45	$s_4 = \text{"潜在株式調整後 1 株当たり当期純利益 (円)"}$
自己資本比率 (%)	6.0	6.3	6.0	$s_5 = \text{"自己資本比率 (%)"}$

$s_6 = \text{"回次 決算年月 1 株当たり ..."} \quad s_7 \quad s_8 \quad s_9 \quad s_{10} = \text{"第81期 2018年3月"}$

Target Cell

Positive samples: $\{(q, s_4), (q, s_{10})\}$
 Negative samples: $\{(q, s_1), (q, s_2), (q, s_3), \dots\}$

Results and Discussions



Ours(w/o FT) < GPT < Ours(w/ FT)

- Our proposed pipeline outperforms GPT-4o, achieving near-human evaluation scores.
- Domain-specific contrastive learning enabled finer cell discrimination.

TF-IDF improved the cell-extraction performance.

- Word-level cues helped extract the row and column for each question.

Non-expert topped accuracy.

- Some companies publish their FY 2023 results based on data from March 2024; unaware of such economic knowledge, the annotator made errors.