第265回 自然言語処理研究発表会

J-RAGBench: 日本語RAGにおけるGenerator評価ベンチマークの構築

板井 孝樹　長谷川 駿一　山本 勇太　峰岸 剛基　大槻 真輝

株式会社 neoAI

目的

RAGのGeneratorの多様な能力を，**同一条件下で体系的に評価可能な枠組み**の構築

発表内容

RAGのGenerator評価ベンチマーク **J-RAGBench** の提案

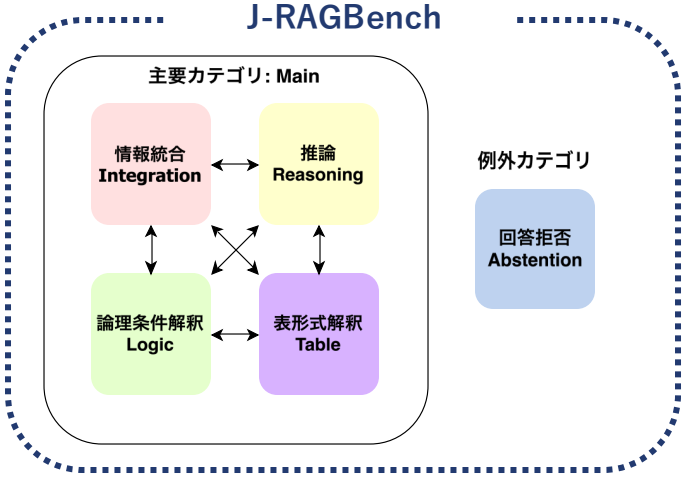

貢献

- Retrieverに依存しない条件での評価により，**Generatorの純粋な外部文書参照能力の評価をするベンチマーク**を構築
- RAGの実運用に近い設計で，**Generatorの能力観点別の横断比較**を実現

⇒ 実運用時のモデル選定指針 ・ RAG特化モデル構築の指標 を提供

Index

Index

検索拡張生成：RAG (Retrieval Augmented Generation)

Retrieval　　：外部文書集合から検索器により関連文書集合を取得
Generation　：LLMが関連文書集合に基づき質問に対する回答を生成

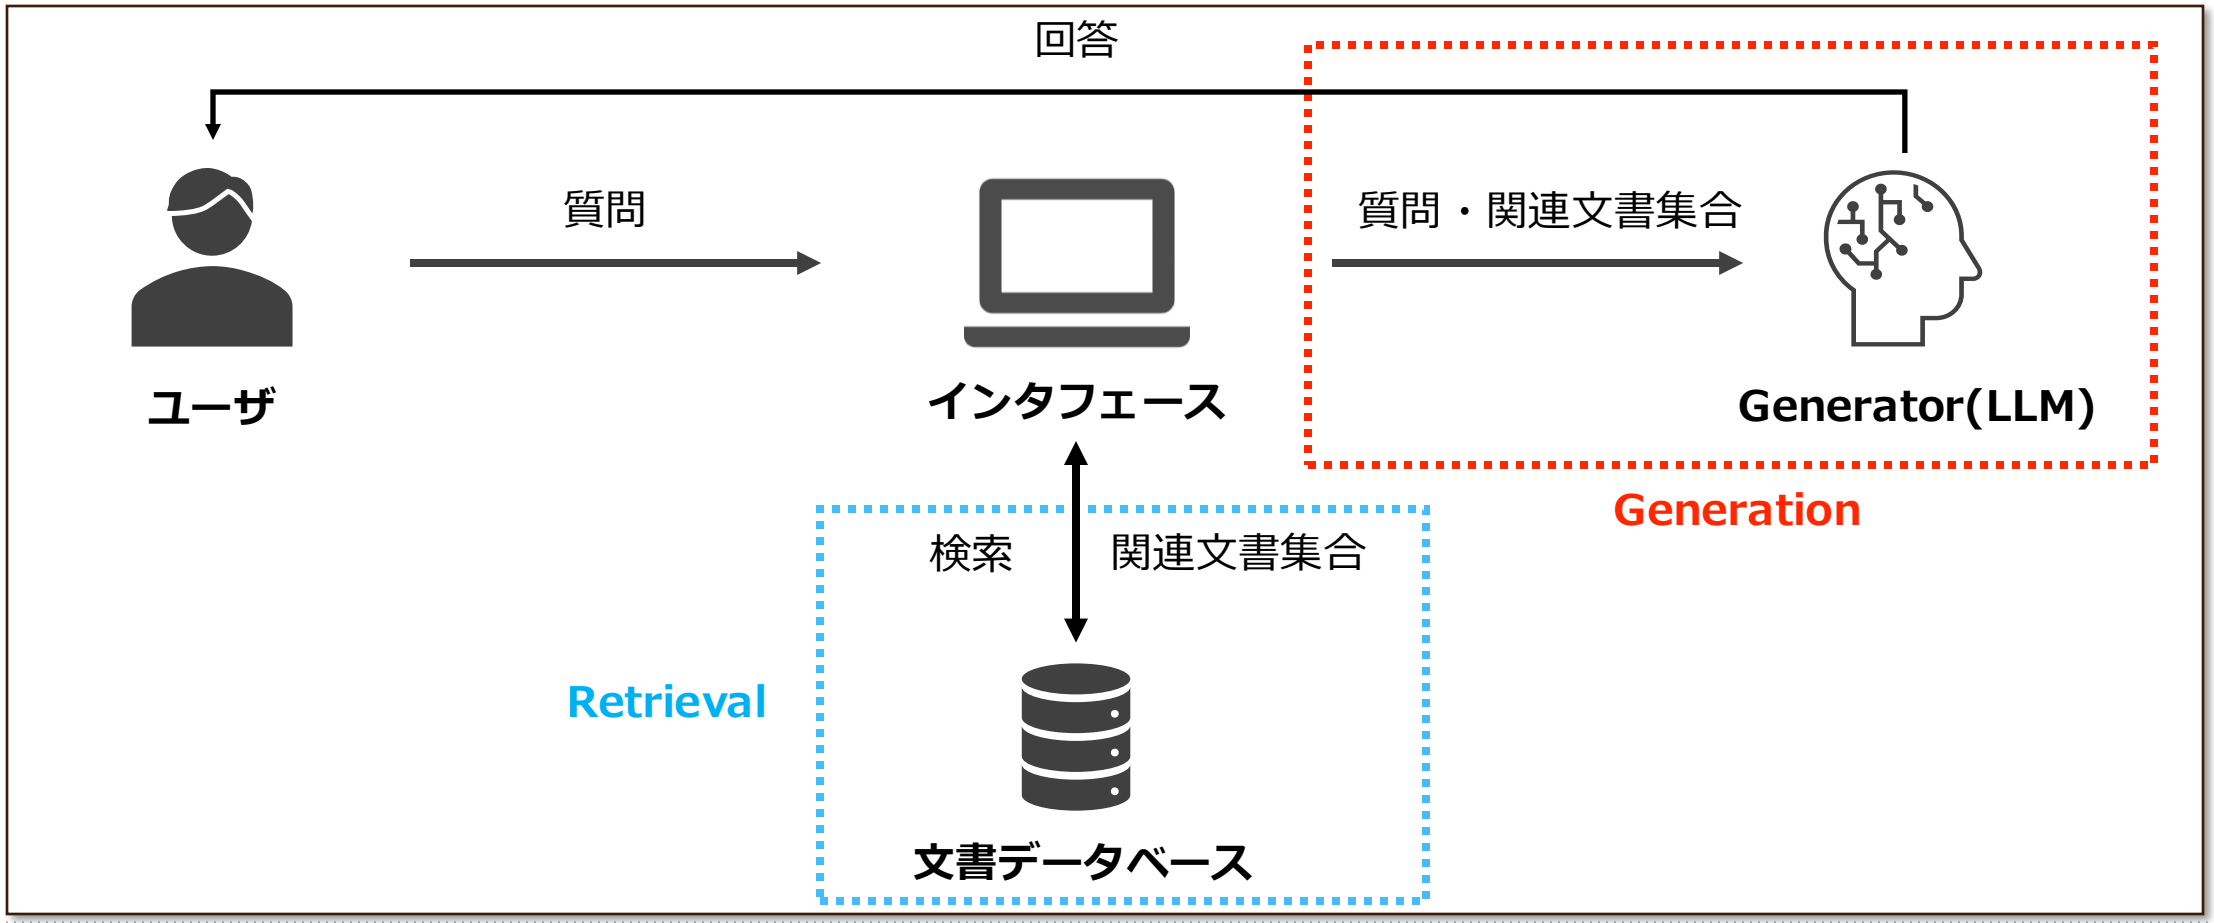

検索拡張生成：RAG (Retrieval Augmented Generation)

Retrieval　　：外部文書集合から検索器により関連文書集合を取得
Generation　：LLMが関連文書集合に基づき質問に対する回答を生成

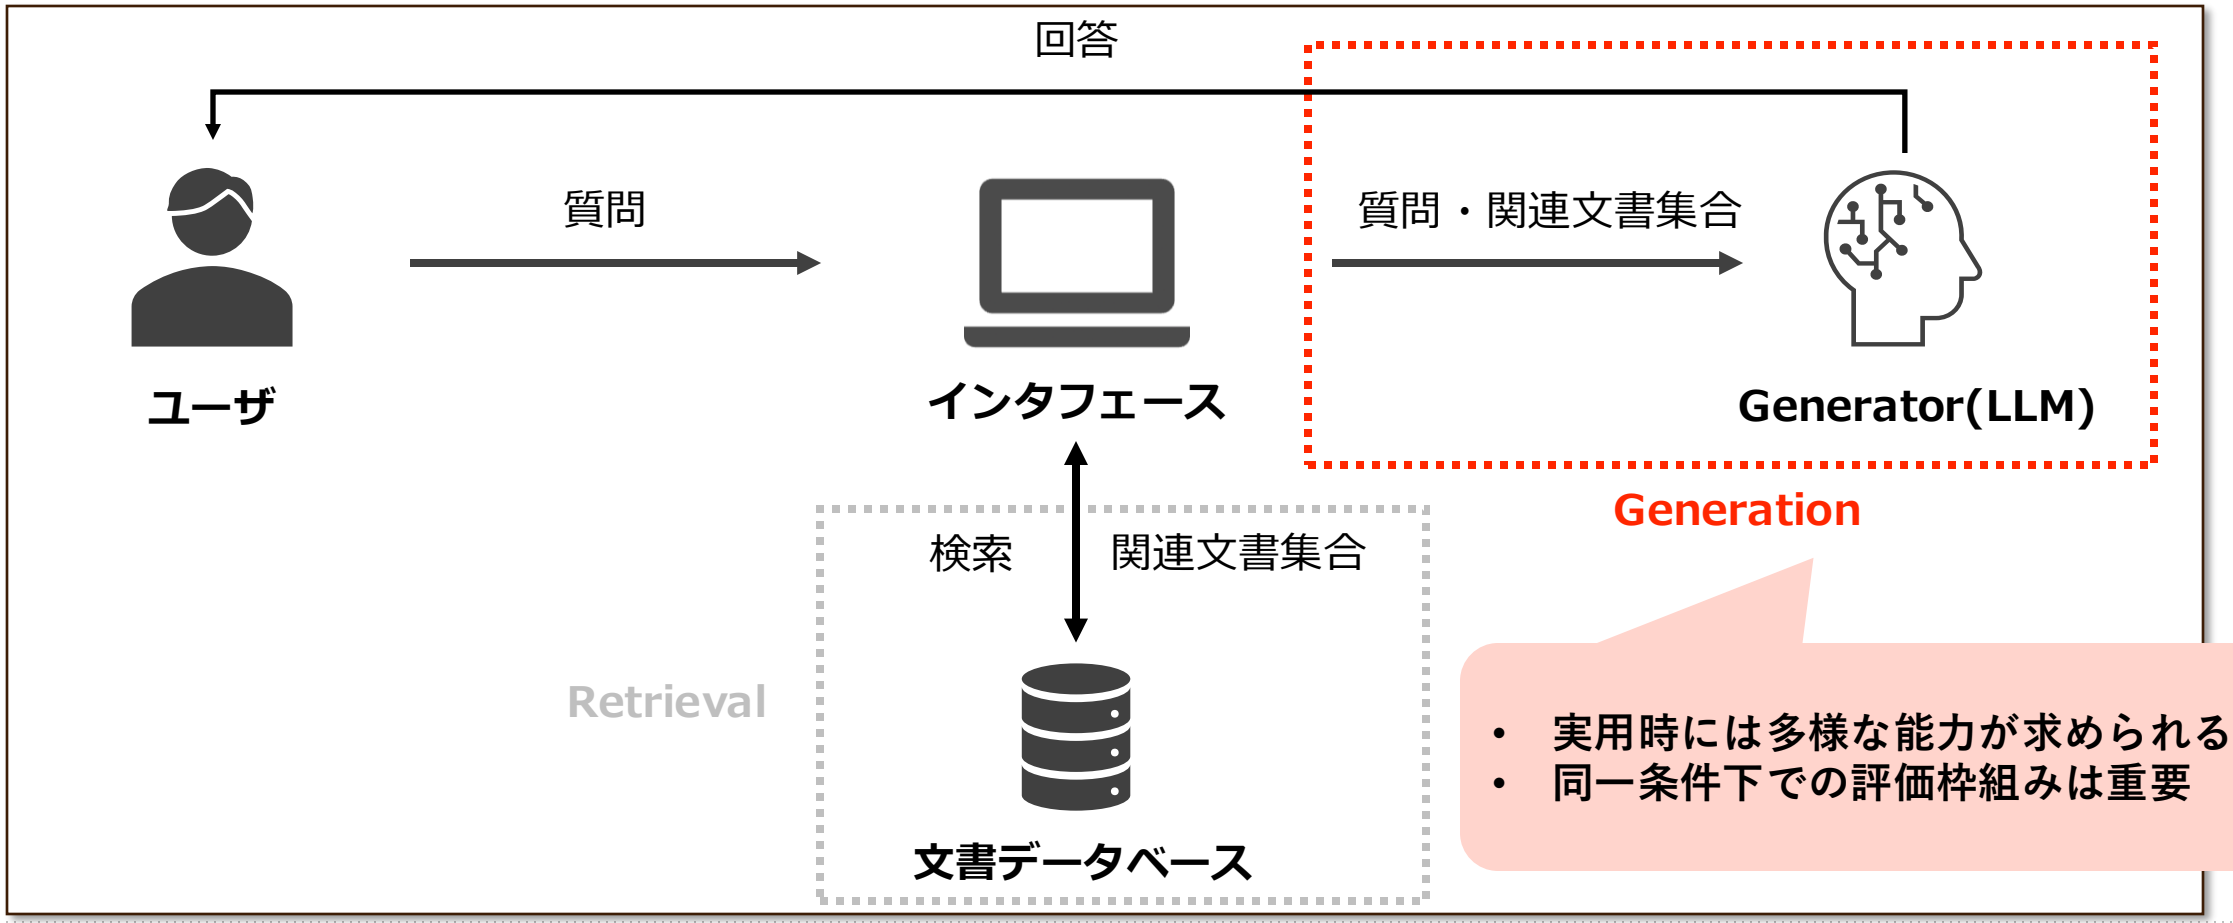

既存研究： Generator 評価ベンチマーク （英語）

FRAMES

事実性・検索能力・推論の3観点を評価

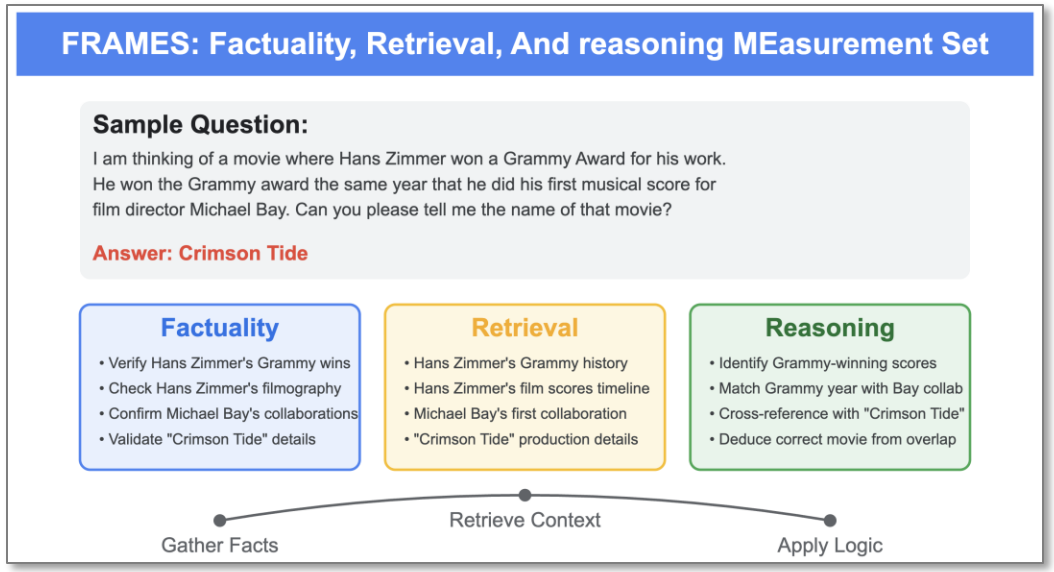

RGB

ノイズ頑健性・情報統合・反事実頑健性・回答拒否の4観点を評価

ノイズ頑健性

情報統合

回答拒否

反事実頑健性

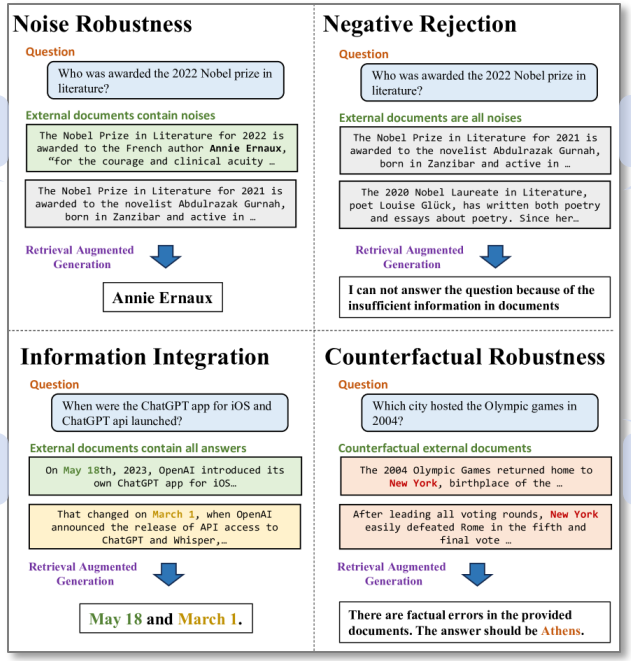

既存研究： Generator 評価ベンチマーク（日本語）

Allganize RAG Leaderboard

図表を含む実ユースケースを想定したQA

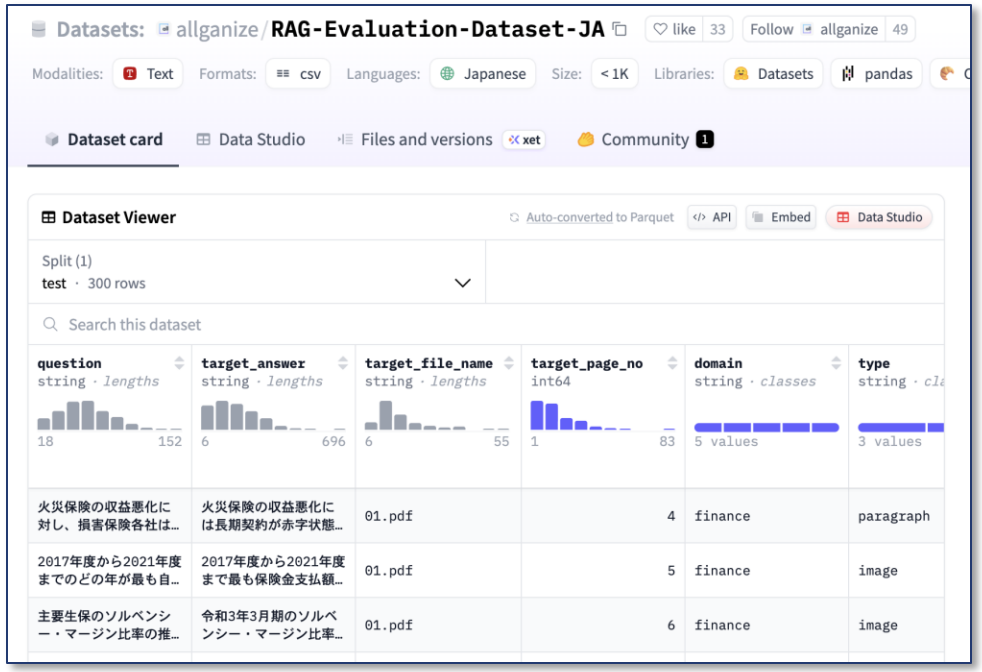

実在しないエンティティや出来事に関する合成文書を用いたRAGベンチマーク

架空シナリオに基づくQAによりLLMの事前学習で得た知識による回答を排除
⇒ Generatorの純粋な外部文書参照能力を評価

リークの可能性を考慮してデータは非公開

SB Intuitions

実運用時のRAGで頻出する誤答パターン

複雑な表を正しく解釈できない

部門	四半期	売上および利益 (百万円)					
		国内		海外		合計	
		売上	利益	売上	利益	売上	利益
電子機器	Q1	3000	900	2000	600	5000	1500
	Q2	3200	950	2100	650	5300	1600
	Q3	3400	1000	2200	700	5600	1700
	Q4	3600	1050	2300	750	5900	1800
家電	Q1	1800	500	1200	400	3000	900
	Q2	1900	550	1300	450	3200	1000
	Q3	2000	600	1400	500	3400	1100
	Q4	2100	650	1500	550	3600	1200

大規模な表・結合セルなど

表の読み取り x マルチホップ推論

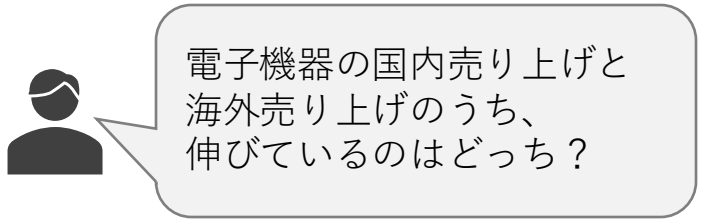

抽出した情報⇒多段階の推論を要する

情報抽出から発展したタスクなど

答えられないのに答えてしまう

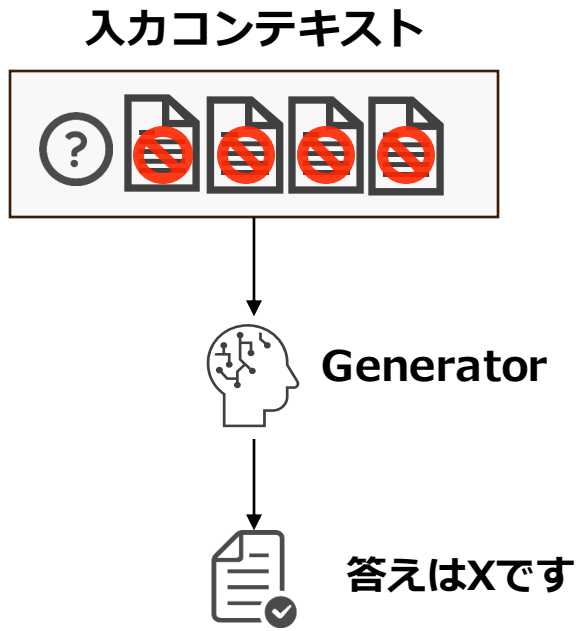

根拠情報が存在しない場合は
素直に回答を拒否してほしい

研究目的

課題意識

実運用時は，Generatorには以下が求められる

- **より多様な能力（ex. 表の読み取り，適切な回答拒否など）**
- **同時に複数の能力を求められるユースケースの対応**

既存手法の課題

- ✓ 評価する能力が限定的
- ✓ 複数能力を同時かつ網羅的に評価する枠組みの整備は不十分

研究目的

- 実運用時に得た課題やユースケースを加味した**能力観点の整理・体系化**
- **複数観点が共起**する場合を含めた評価枠組みの整備

Index

J-RAGBench (Japanese RAG Generator Benchmark)

- 5つの**「評価カテゴリ」**を定義：金融・製造業などの多様な業界にRAGシステムを導入する過程で直面した課題・実運用時のユースケースを反映
- 「評価カテゴリ」ごとにユースケースを想定した**「評価観点」**に細分化
- **架空シナリオに基づくQA**で，**評価観点2種までの全組み合わせを網羅**する設計
- HuggingFace Hubにて公開：neoai-inc/Japanese-RAG-Generator-Benchmark

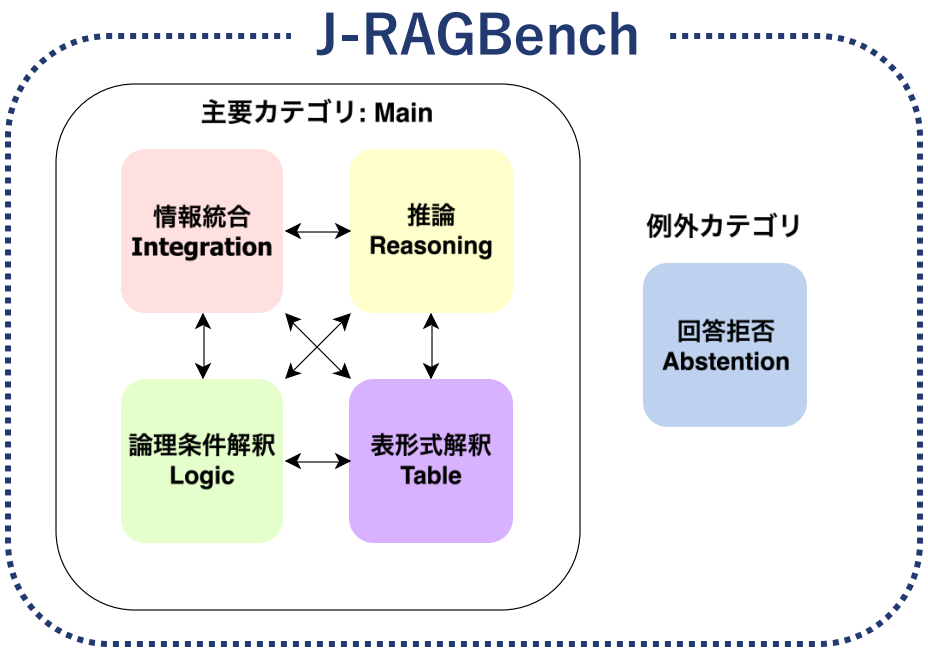

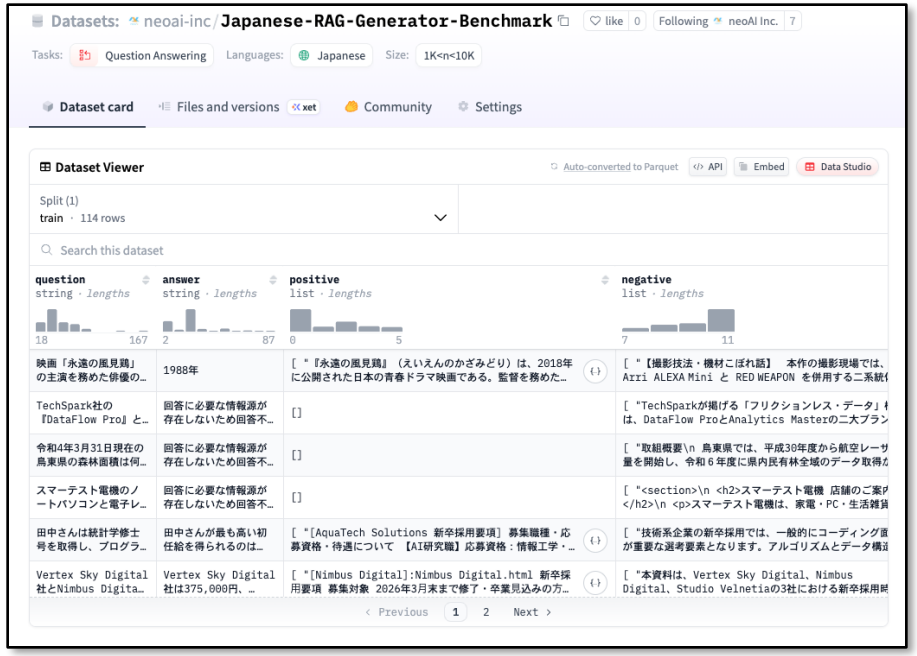

ベンチマークの構成

評価データセットの各QAは以下で構成

評価データセットの構成要素

構成要素	説明
評価観点集合	QAの評価観点 (1~2つ)
質問	評価観点集合に基づく質問
関連文書集合	• 質問の根拠となる文書集合 • チャンク単位で分割済み
非関連文書集合	• 質問の根拠にならない文書集合 • 質問との意味的類似度が高いor キーワードが含まれる文書 • チャンク単位で分割済み • 6~8チャンク
正答	質問に対する正答

※ 1チャンク: 512トークン程度(tiktokenを用いて計測)

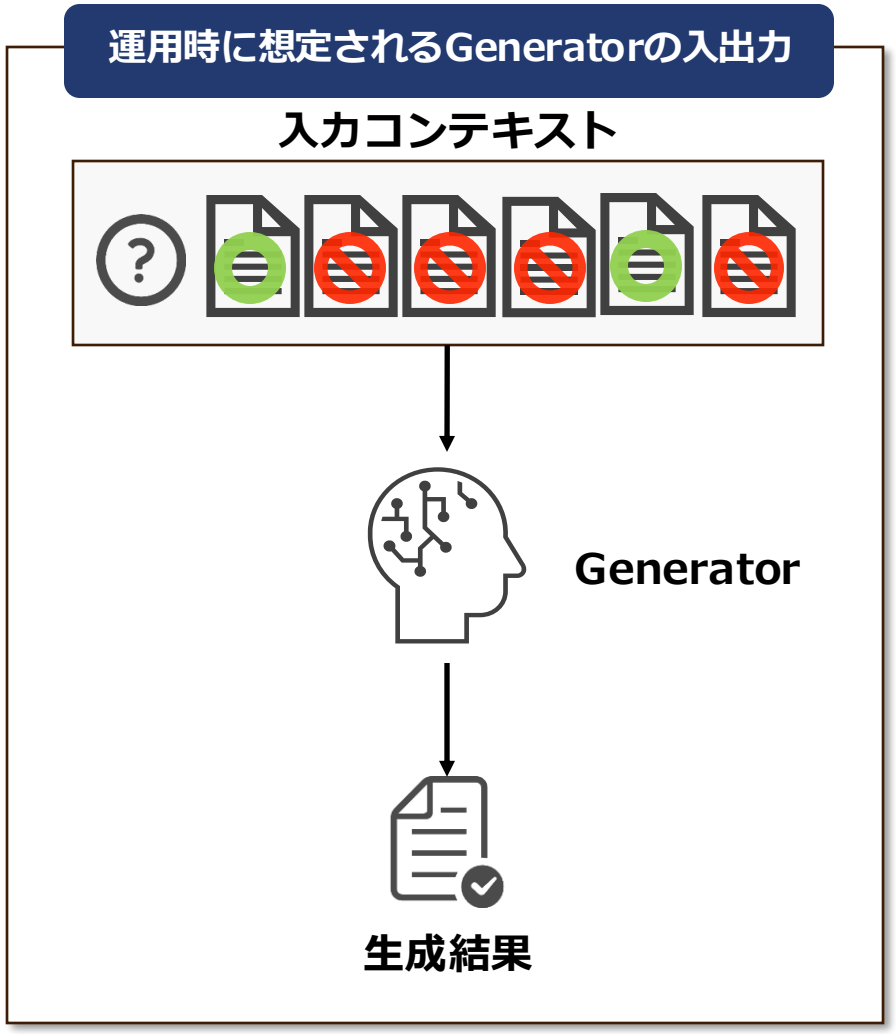

J-RAGBench の評価カテゴリ・評価観点

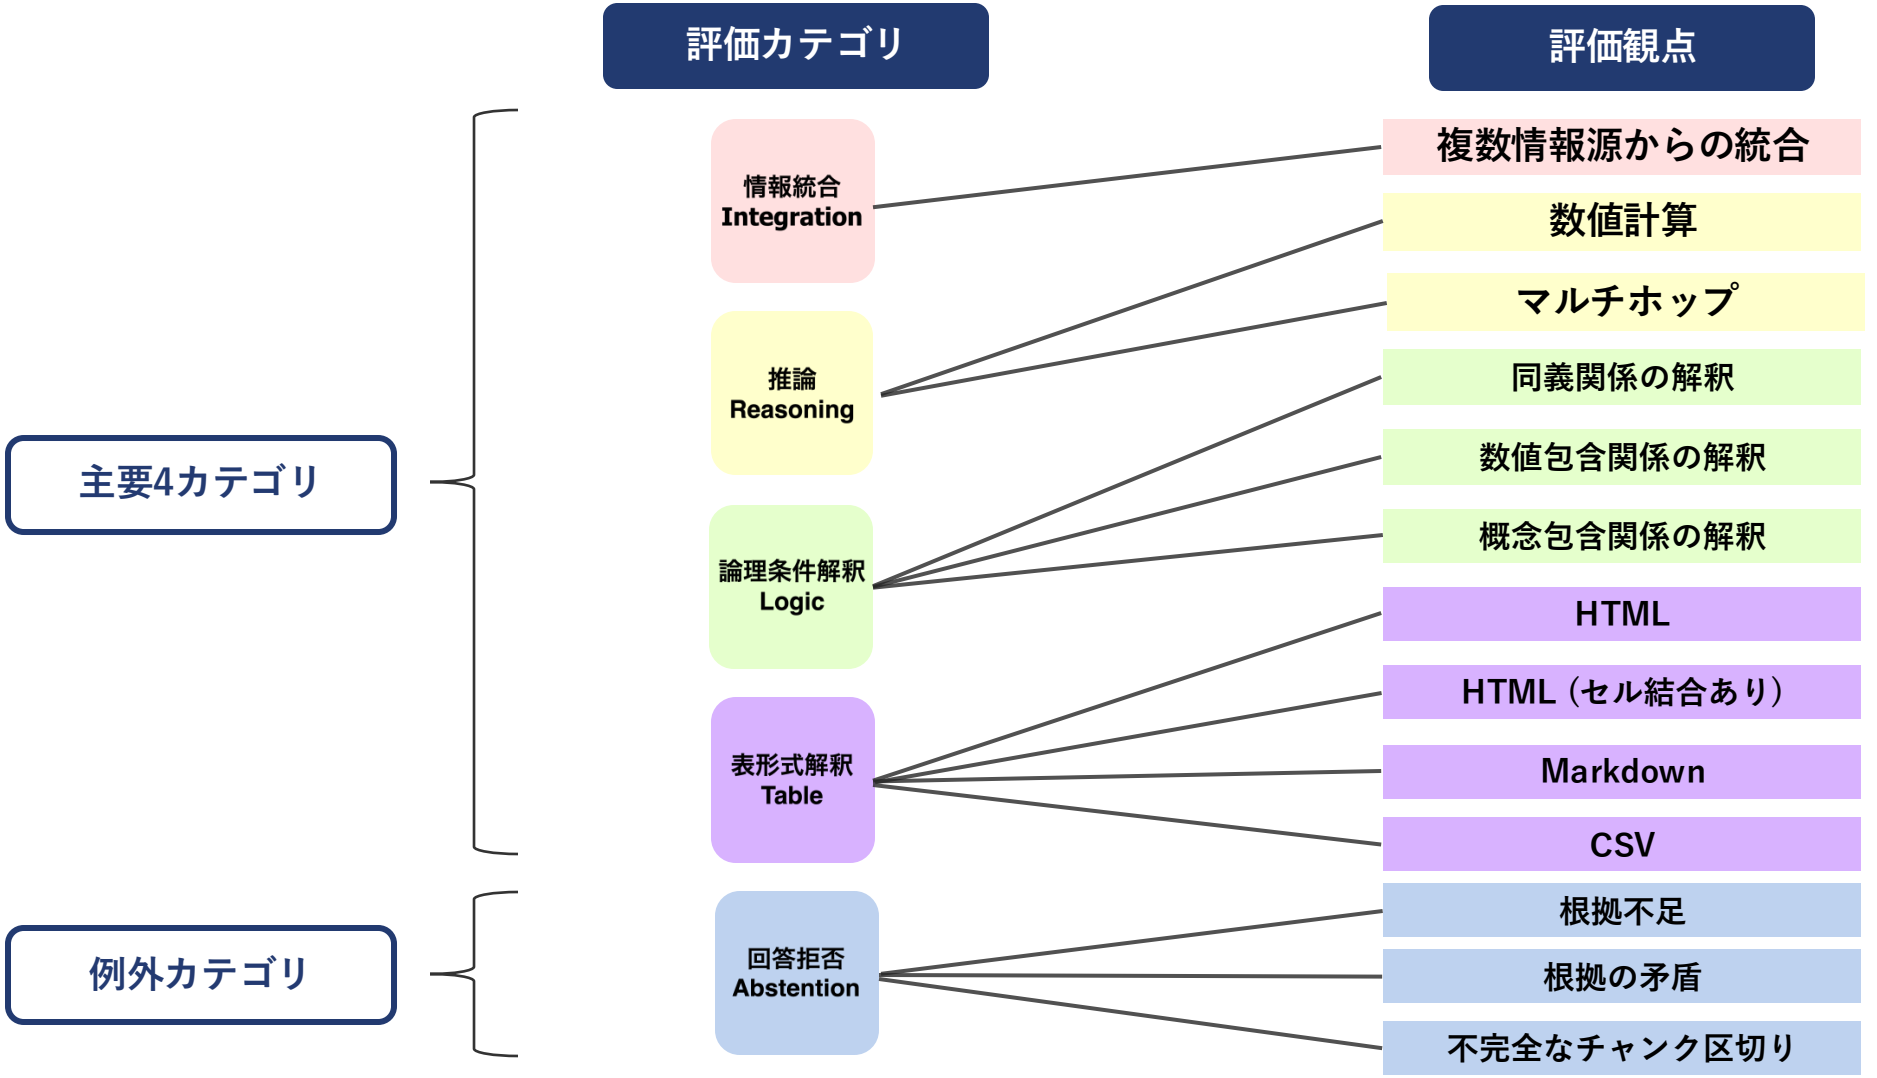

主要カテゴリ①：情報統合 (Integration)

概要 **根拠情報が複数の文書に分散 ⇨ 抽出・統合して回答する能力**

□ 複数の情報源からの統合：2 ~ 3文書からの情報源の統合を対象としたQA

例：複数の情報源からの統合

Vertex Sky Digital 社とNimbus Digital 社の**デザイナー職の新卒の月給**はいくら？

【Vertex Sky Digital 新卒採用要項】
…
デザイナー職34万円

【VSD社 中途採用要項】採用情報 募集要項
担当いただく業務概要
…

【初任給】 初任給（しょにんきゅう）は、学校を卒業して正規雇用されるようになった人が …

【Nimbus Digital 新卒採用要項】
アニメータ/**デザイナー**:
月額基本給：26 万円

Vertex Sky Digital 社は34万円,
Nimbus Digital 社は26万円です.

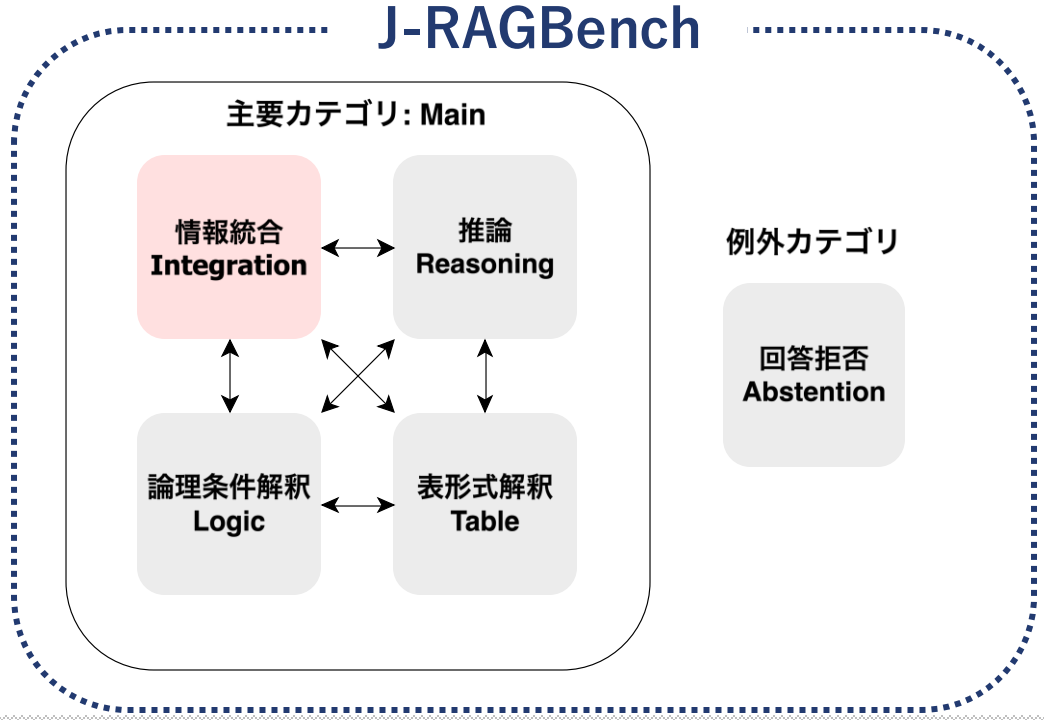

主要カテゴリ②：推論 (Reasoning)

概要 **抽出された情報を踏まえて，多段階推論や数値計算などを実行する能力**

- **数値計算:** 四則演算・利益率等の指標計算
- **マルチホップ推論:** 直接的な記載がない結論を導く (関連研究: HotpotQA, JEMHopQA)

例：マルチホップ推論

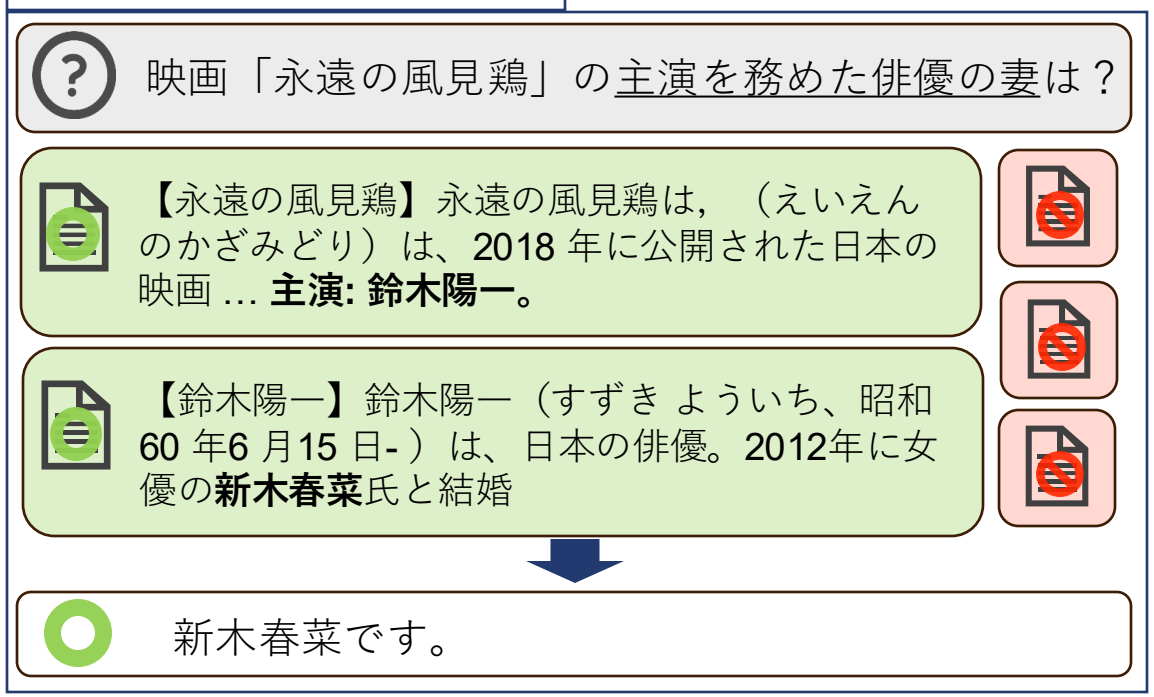

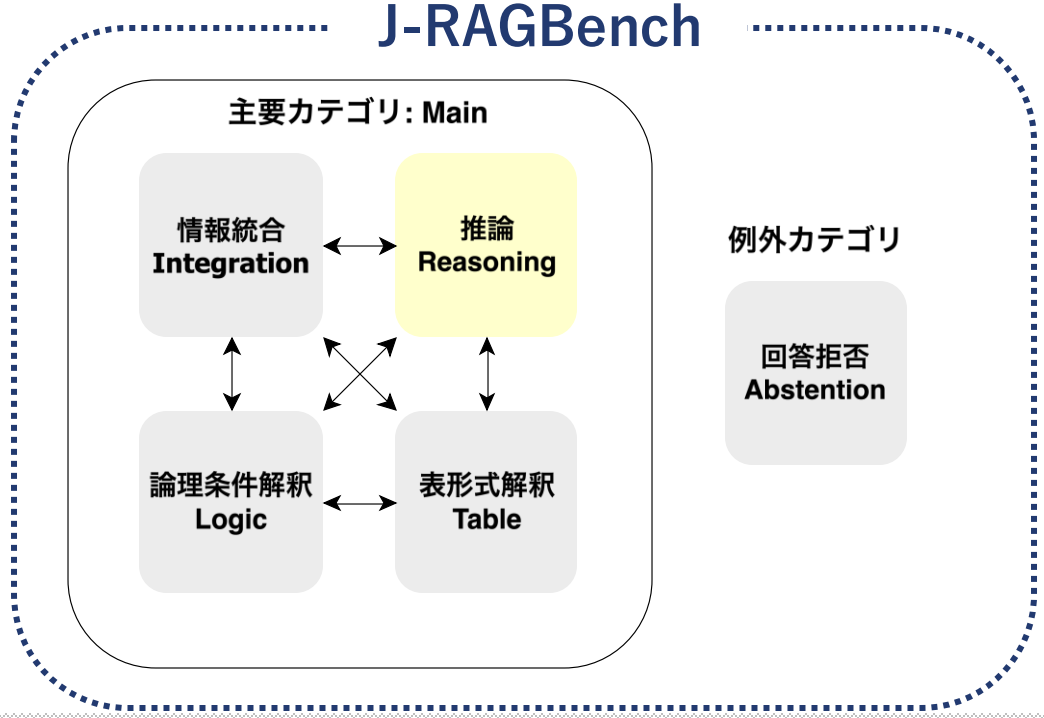

主要カテゴリ③：論理関係解釈（Logic）

概要 **質問・関連文書間での語彙や表現の差異を解釈し情報を抽出・回答する能力**

- **同義関係の解釈**　：質問と関連文書の間で異なる表現を同義であると解釈
- **数値包含関係の解釈**：質問と関連文書の間での数値的な包含関係を解釈
- **概念包含関係の解釈**：質問と関連文書の間での概念的な包含関係を解釈

例：同義関係の解釈

株式会社統計解析Labの平成25年度の研究支援金収入は何億円ですか

【平成20年度 予算報告】
研究支援金収入：**7,616百万円**

76億1,600万円です。

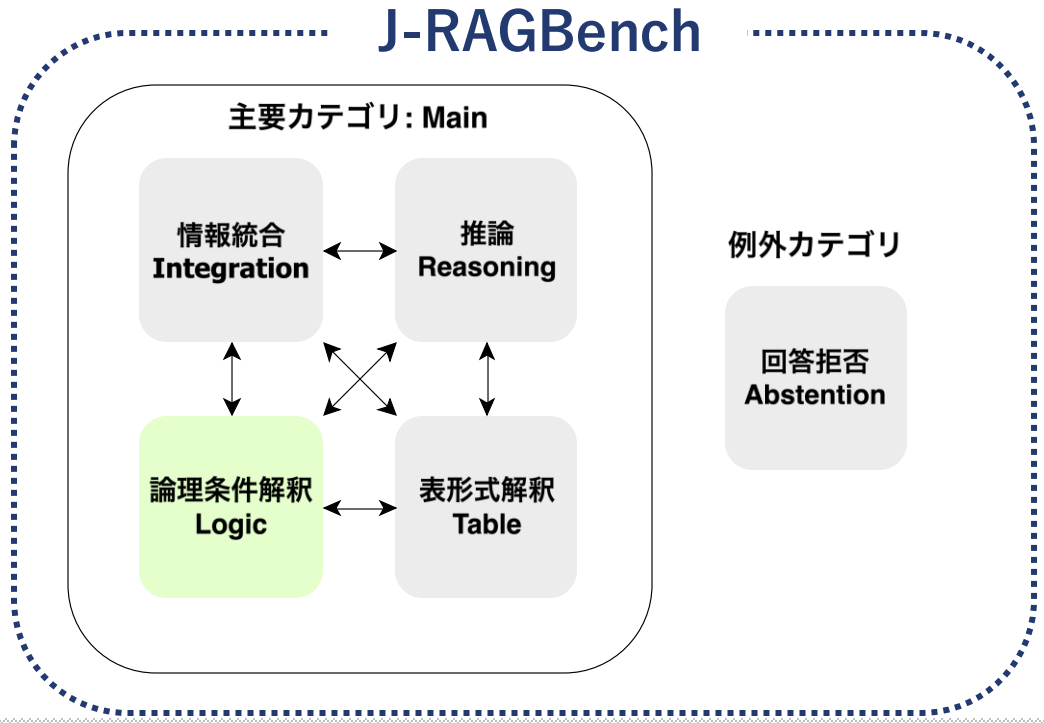

主要カテゴリ③：論理関係解釈（Logic）

概要 **質問・関連文書間での語彙や表現の差異を解釈し情報を抽出・回答する能力**

- □ 同義関係の解釈 ：質問と関連文書の間で異なる表現を同義であると解釈
- ▶ **□ 数値包含関係の解釈 ：質問と関連文書の間での数値的な包含関係を解釈**
- □ 概念包含関係の解釈 ：質問と関連文書の間での概念的な包含関係を解釈

例：数値含関係の解釈

27歳で2件の社内プロジェクト提案経験を有する佐藤主任研究員は参加資格を満たすか？

【参加資格】
年齢: **満24歳以上**
社内プロジェクト提案経験: **3件以上**
…

参加資格を満たさない。参加には社内プロジェクト提案経験が3件以上必要であるが, 2件で満たさない。

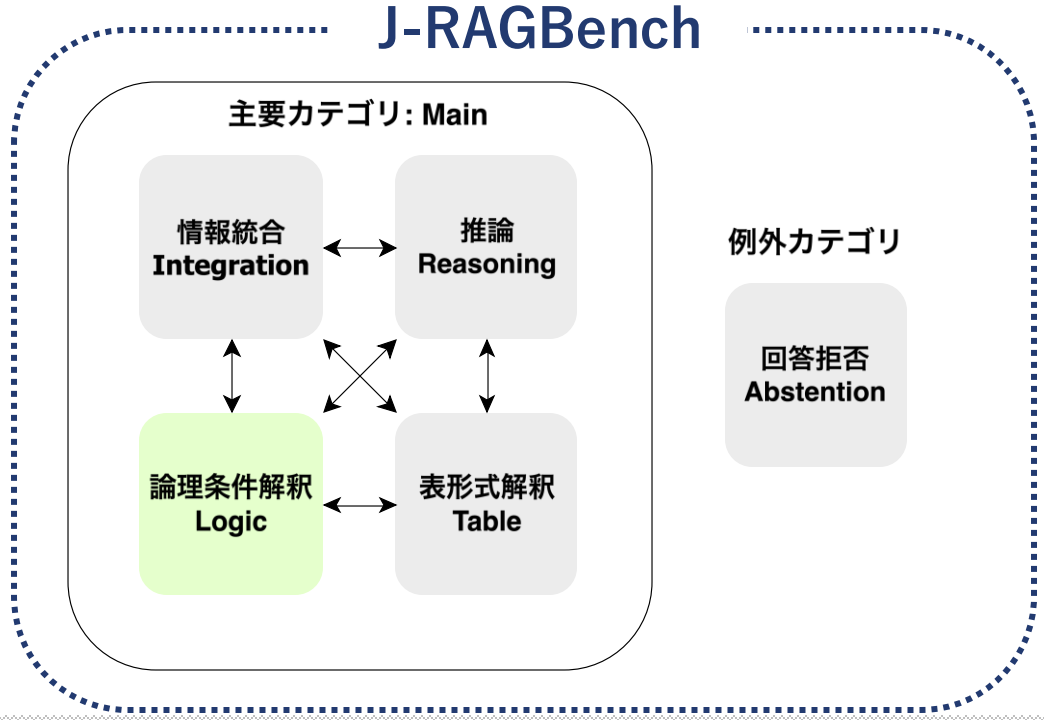

主要カテゴリ③：論理関係解釈（Logic）

概要 **質問・関連文書間での語彙や表現の差異を解釈し情報を抽出・回答する能力**

- 同義関係の解釈　：質問と関連文書の間で異なる表現を同義であると解釈
- 数値包含関係の解釈：質問と関連文書の間での数値的な包含関係を解釈
- **概念包含関係の解釈**：質問と関連文書の間での概念的な包含関係を解釈

例：概念包含関係の解釈

A325室でオンライン会議を行うことは可能ですか？

【A325室禁止事項】… **電子機器の持ち込み及び使用は厳禁である。**

A325室では電子機器の使用が禁止されており、オンライン会議を行うことはできません。

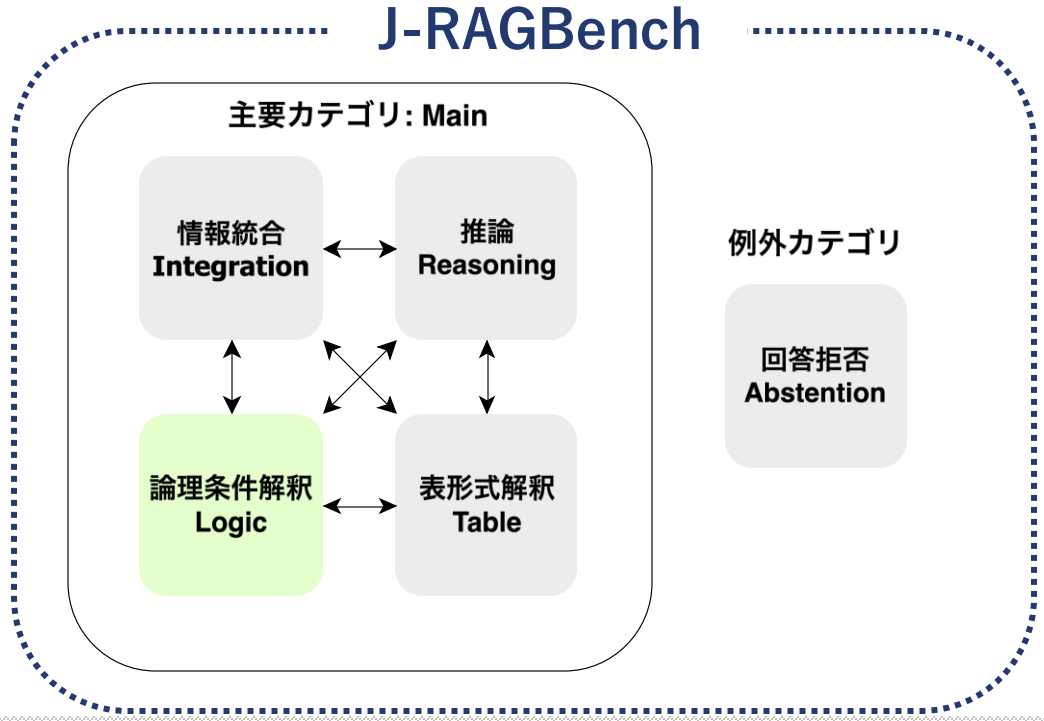

主要カテゴリ④：表形式解釈（Table）

概要 関連文書の根拠の記述が表形式 ⇒ 根拠の情報を解釈・抽出する能力

- HTML形式
- Markdown形式
- HTML形式(セル結合あり)
- CSV形式

例：Markdown形式

2019年から2021年にかけて，グローバリンク社の海外支店からの帰任数は増加したか？

【グローバリンク社 帰任者数の推移】
本レポートでは，…

期間	2017	2018	2019	2020	2021
総数(人)	1,788	1,891	2,003	368	50

いいえ、 2,003人から50人へ減少しています。

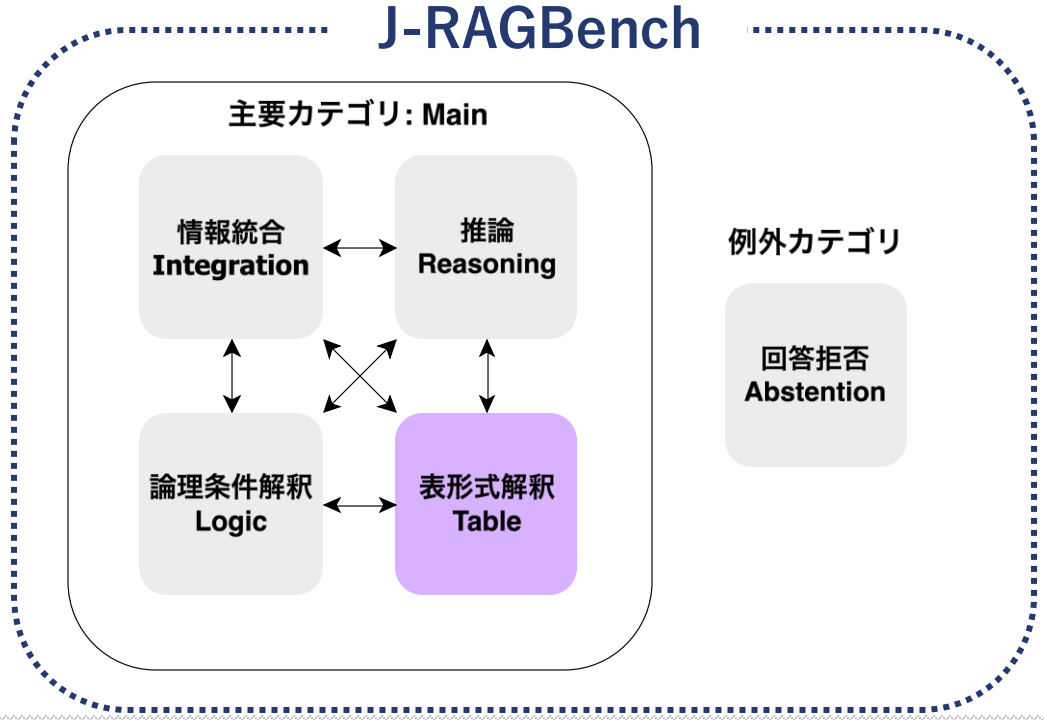

例外カテゴリ：回答拒否（Abstention）

概要 **回答不可である特定の状況下において，適切に回答を拒否する能力**

- **根拠不足:** 関連文書集合が得られなかった場合
- **根拠の矛盾:** 根拠になり得る情報が複数存在し，それらが矛盾している
- **不完全なチャンク区切り:** 根拠がチャンク分割の境界に存在 ⇒ 不完全な根拠情報

例：根拠不足

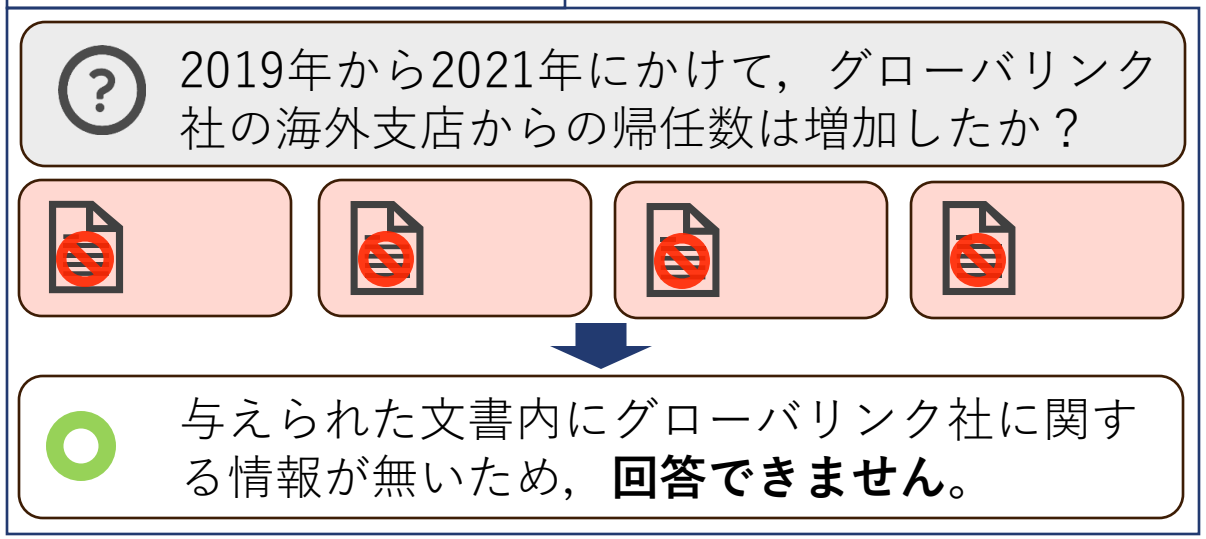

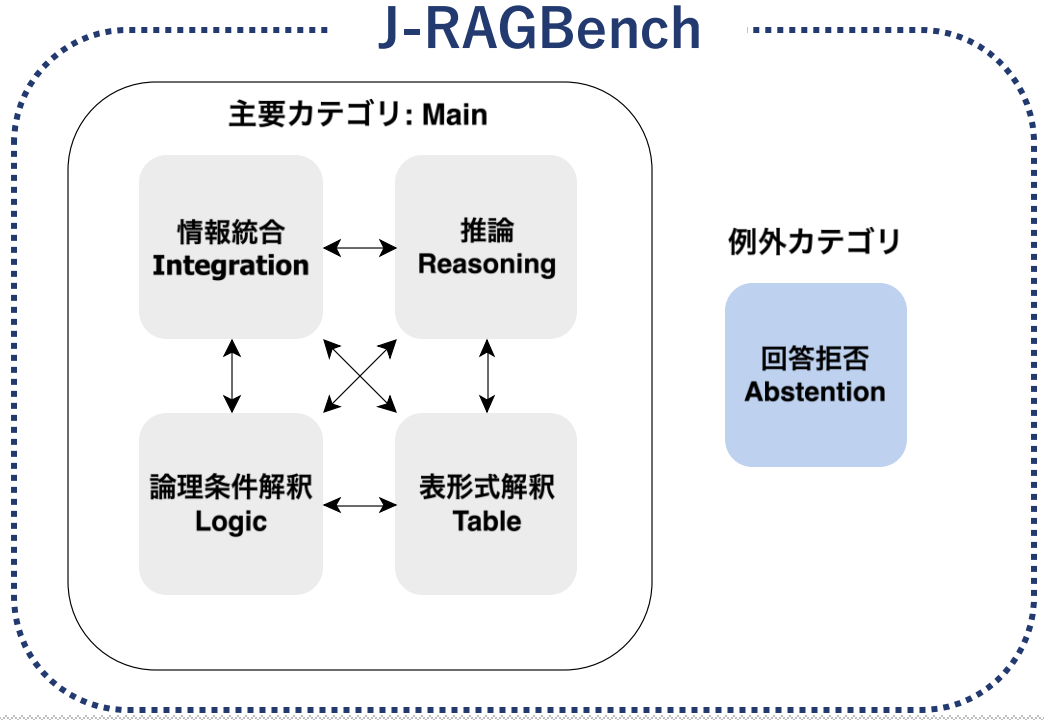

例外カテゴリ：回答拒否（Abstention）

概要 **回答不可である特定の状況下において，適切に回答を拒否する能力**

- **根拠不足:** 関連文書集合が得られなかった場合
- **根拠の矛盾:** 根拠になり得る情報が複数存在し，それらが矛盾している
- **不完全なチャンク区切り:** 根拠がチャンク分割の境界に存在 ⇒ 不完全な根拠情報

例：根拠の矛盾

新人研修の参加に必要な統一英語力試験のスコアは？

【新人研修 2021】参加に資する英語力の指標として、**統一英語力試験650点以上の取得が必須**…

【研修 概要】参加にあたっては、**統一英語力試験550点以上が条件**となっている…

根拠に当たる情報が複数存在し，これらが矛盾した内容でのため正確にお伝えできません。参考として…

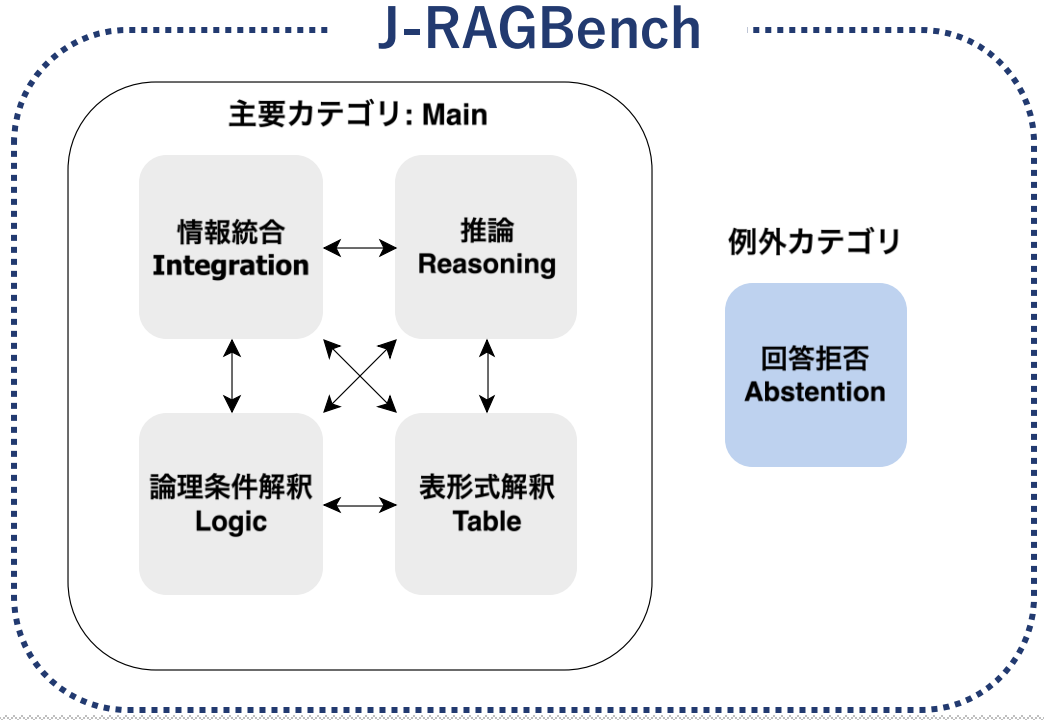

例外カテゴリ：回答拒否（Abstention）

概要 **回答不可である特定の状況下において，適切に回答を拒否する能力**

- **根拠不足:** 関連文書集合が得られなかった場合
- **根拠の矛盾:** 根拠になり得る情報が複数存在し，それらが矛盾している
- **不完全なチャンク区切り:** 根拠がチャンク分割の境界に存在 ⇒ 不完全な根拠情報

例：不完全なチャンク区切り

医療用電子機器の安全管理において必要な条件は？

近年、医療現場では…
医療用電子機器の安全管理に必要な条件は、
以下の５つに集約される。**（ここで情報が途切れる）**

関連する情報が途中で途切れており，正確な情報を**回答できません。**

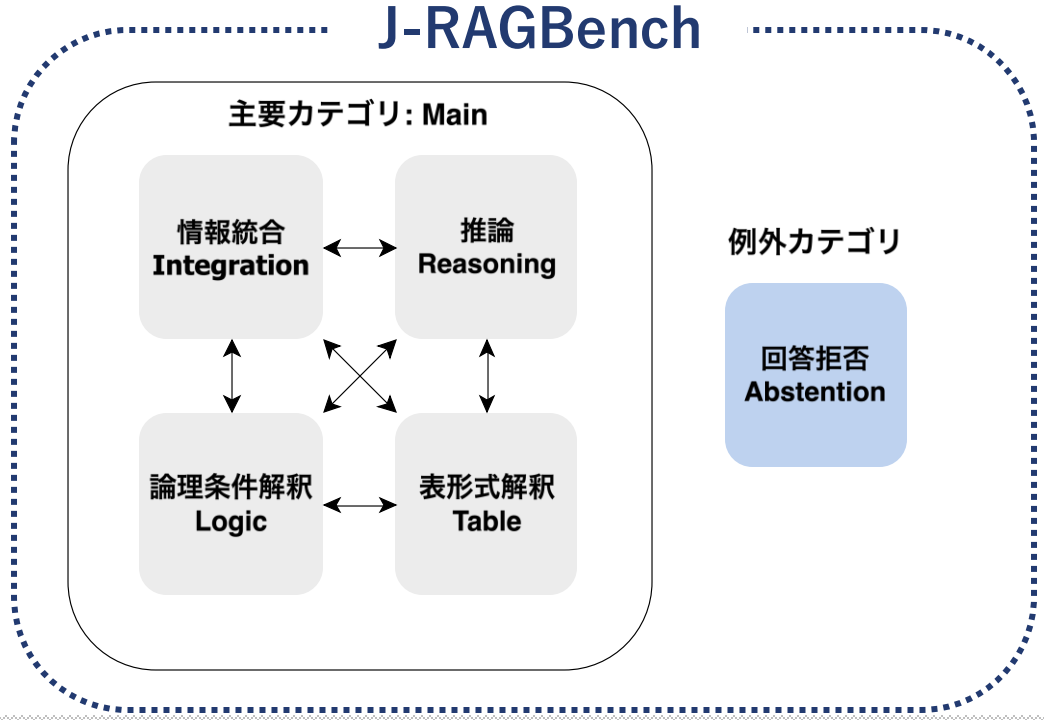

作問手順

1. 架空QAシナリオの決定

- 架空の企業・製品・人物に基づくシナリオを作成

2. 質問・関連文書・正答の作成

- 評価観点を反映した質問・関連文書・正答を作成
- LLMを用いた合成および人手による整形

3. 非関連文書の作成

- 質問の直接的な根拠にはならないが，キーワードや意味的類似度の高い非関連文書を作成
- LLMを用いた合成および人手による整形

4. 人手フィルタリング

1. 評価観点を適切に反映した質問であるか
2. 関連文書のみを根拠として回答可能か
3. LLMの事前知識のみで回答不可能か
4. 架空情報が実在情報と矛盾していないか

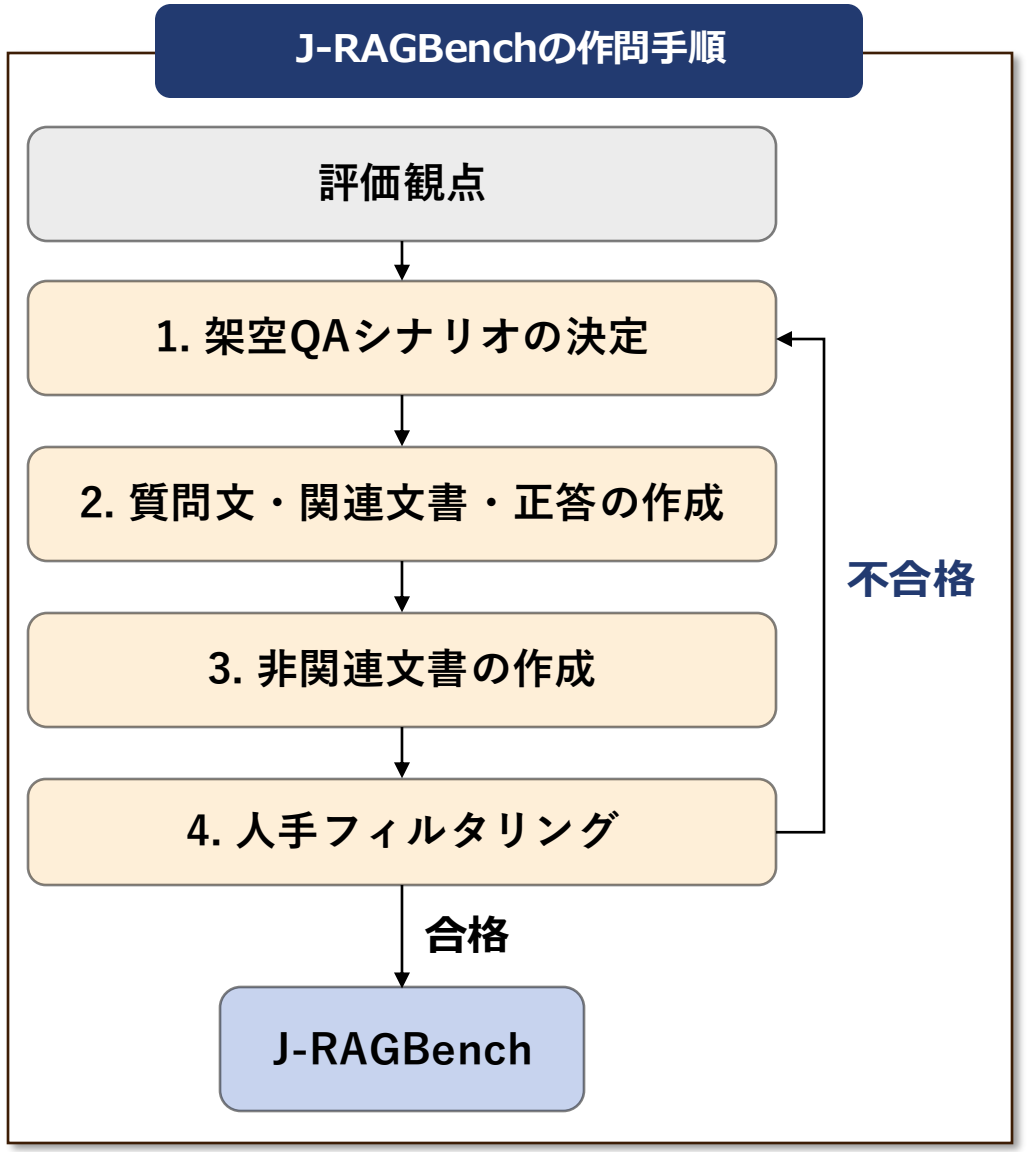

ベンチマークの統計

合計**114問の評価データセット**を構築

- Mainカテゴリ：54問
- Abstention(根拠不足)：
  MainのQAデータから関連文書集合を空集合に変換

J-RAGBenchの評価観点別の問題数

評価カテゴリ	評価観点	問題数
Integration	複数情報源からの統合	12問
Reasoning	マルチホップ推論	12問
	数値計算	11問
Logic	同義関係の解釈	11問
	数値包含の関係	10問
	概念包含関係の解釈	9問
Table	HTML形式	8問
	HTML形式 (セル結合)	9問
	Markdown形式	7問
	CSV形式	7問
Abstention	根拠不足	54問
	根拠の矛盾	3問
	不完全なチャンク区切り	3問

評価方法

LLM-as-a-Judge：LLMを用いた自動評価手法

⇒ Generatorの生成結果と正答の一致性に基づき正誤判定

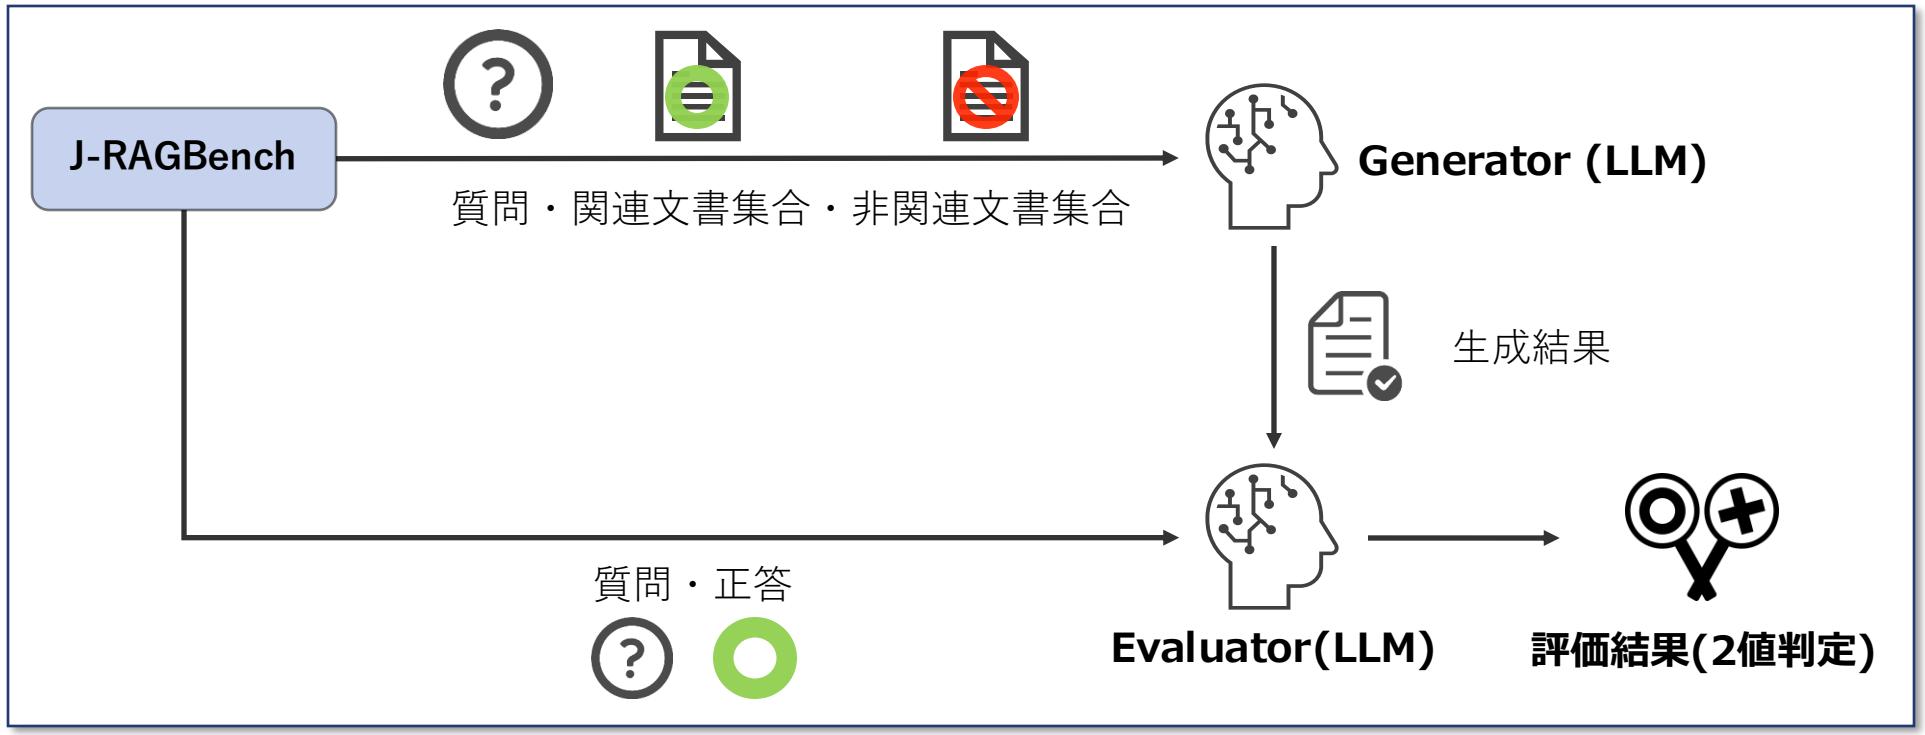

➡ 評価セット全体・評価観点別の**Accuracy (正解率)**を算出

Index

実験概要

J-RAGBenchを用いて日本語を生成可能なAPI提供・オープンウェイトのLLMを評価

評価対象のLLM（左：API提供モデル・右：オープンウェイトモデル）

モデル名	バージョン	開発元	推論モデル
GPT5	2025-08-07	OpenAI	✔
GPT5 mini	2025-08-07	OpenAI	✔
GPT5 nano	2025-08-07	OpenAI	✔
o3	2025-04-16	OpenAI	✔
o4 mini	2025-04-16	OpenAI	✔
GPT 4.1	2025-04-14	OpenAI	
GPT 4.1 mini	2025-04-14	OpenAI	
Gemini 2.5 Flash	2025-05-17	Google	
Gemini 2.5 Pro	2025-05-17	Google	✔
Claude Sonnet 4	2025-05-17	Anthropic	

モデル名	開発元	推論モデル
Llama 3.1 8B Instruct	Meta	
Llama 3.3 70B Instruct	Meta	
Gemma 3 27B Instruct	Google	
Qwen3 235B A22B Instruct	Alibaba	
Qwen3 235B A22B Thinking	Alibaba	✔

実験設定: 生成パラメータ

Generator: 実験対象モデル

- 推論モデルの思考トークンの生成長はいずれも最長に設定
  - 例: reasoning effort: high
- サンプリングパラメータが設定可能なモデルはいずれも以下を設定
  - temperature: 0.0
  - top_p: 1.0
- seed値はいずれも42

Evaluator: 評価器モデル

- GPT 4.1
- 生成パラメータは同上

評価結果: 総合評価

総合正解率：5つの評価カテゴリのAccuracy

✓ Accuracy > 0.9のモデルは無い

✓ 全体的に推論モデルが良好な傾向

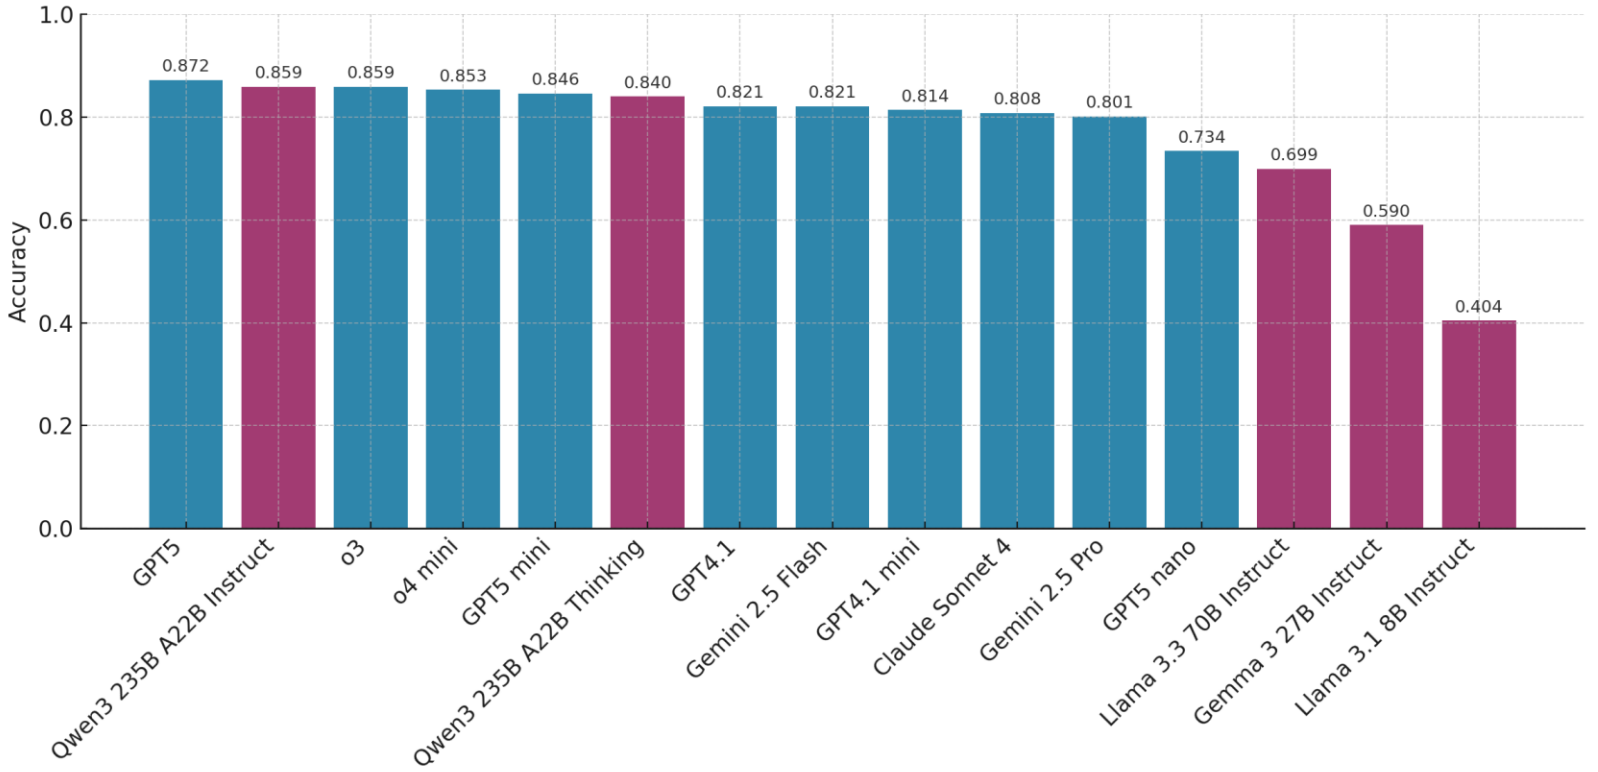

評価結果: 総合評価

総合正解率：5つの評価カテゴリのAccuracy

- ✓ Accuracy > 0.9のモデルは無い
- ✓ 全体的に推論モデルが良好な傾向

GPT5が全体最高性能

Qwen3 235B A22B Instructがオープンウェイトモデルの中では最高性能

中規模程度のオープンウェイトモデルはAPI提供モデルに比べて劣る

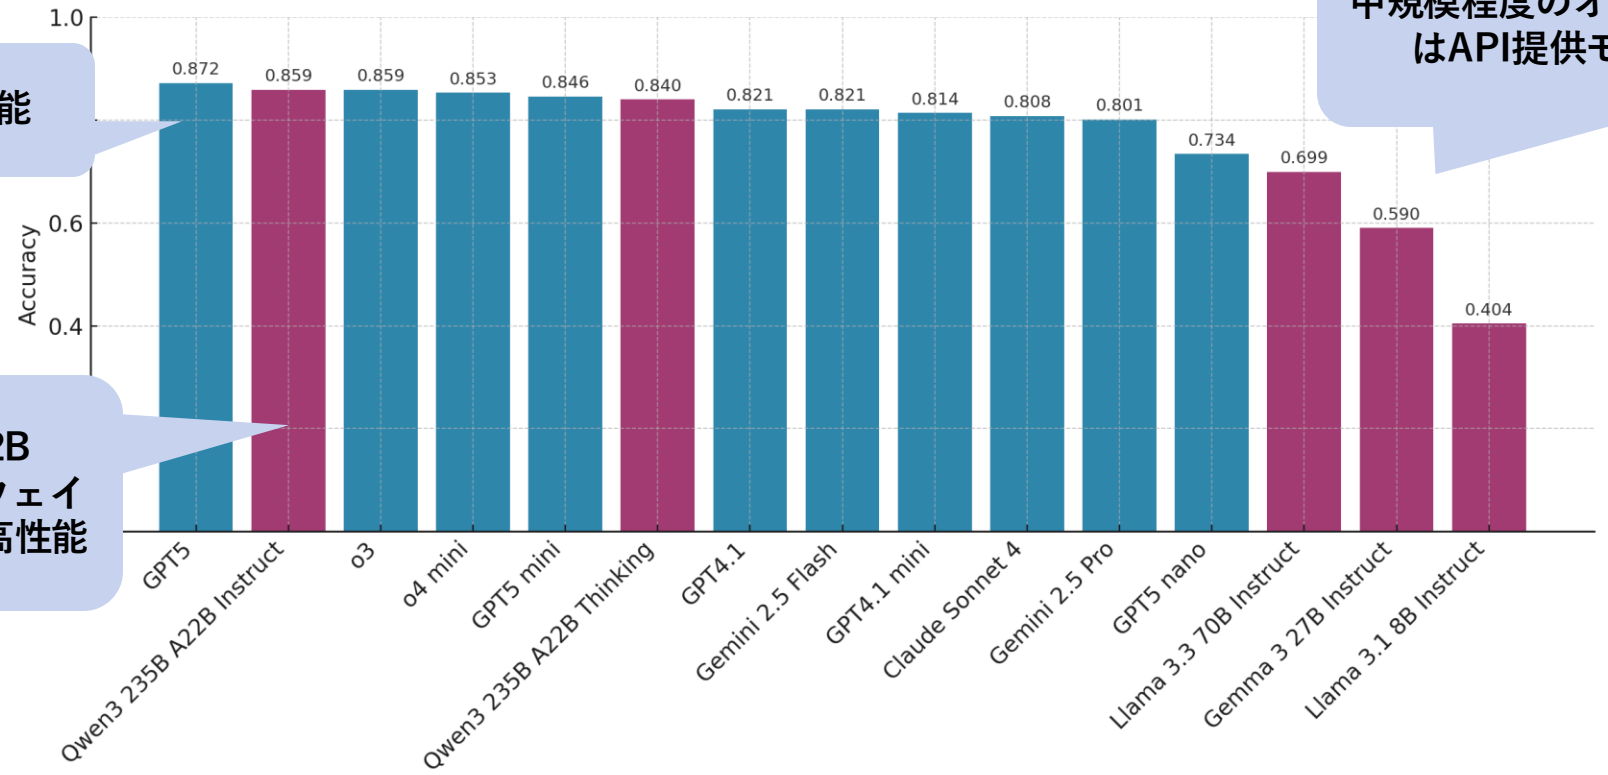

評価結果: Main

主要4カテゴリ(回答拒否を除く)の評価結果

✓ 総合正解率とは順位が変動するも，全体的な傾向は総合評価と共通の傾向

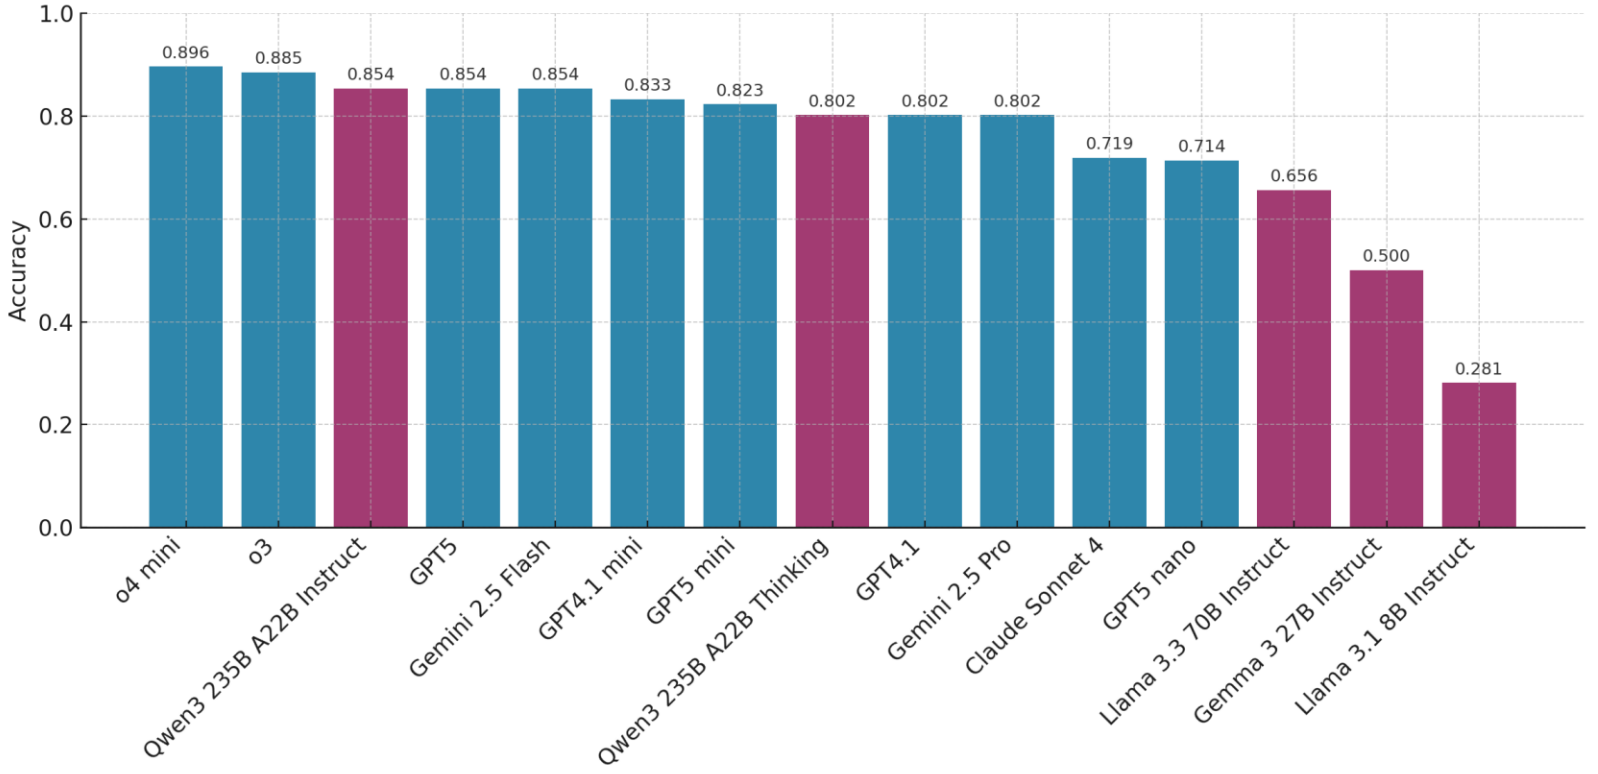

評価結果: Main

主要4カテゴリ(回答拒否を除く)の評価結果

✓ 総合正解率とは順位が変動するも，全体的な傾向は総合評価と共通の傾向

o4-miniが全体最高性能

Claudeは総合評価と比較して約0.1ポイント低い

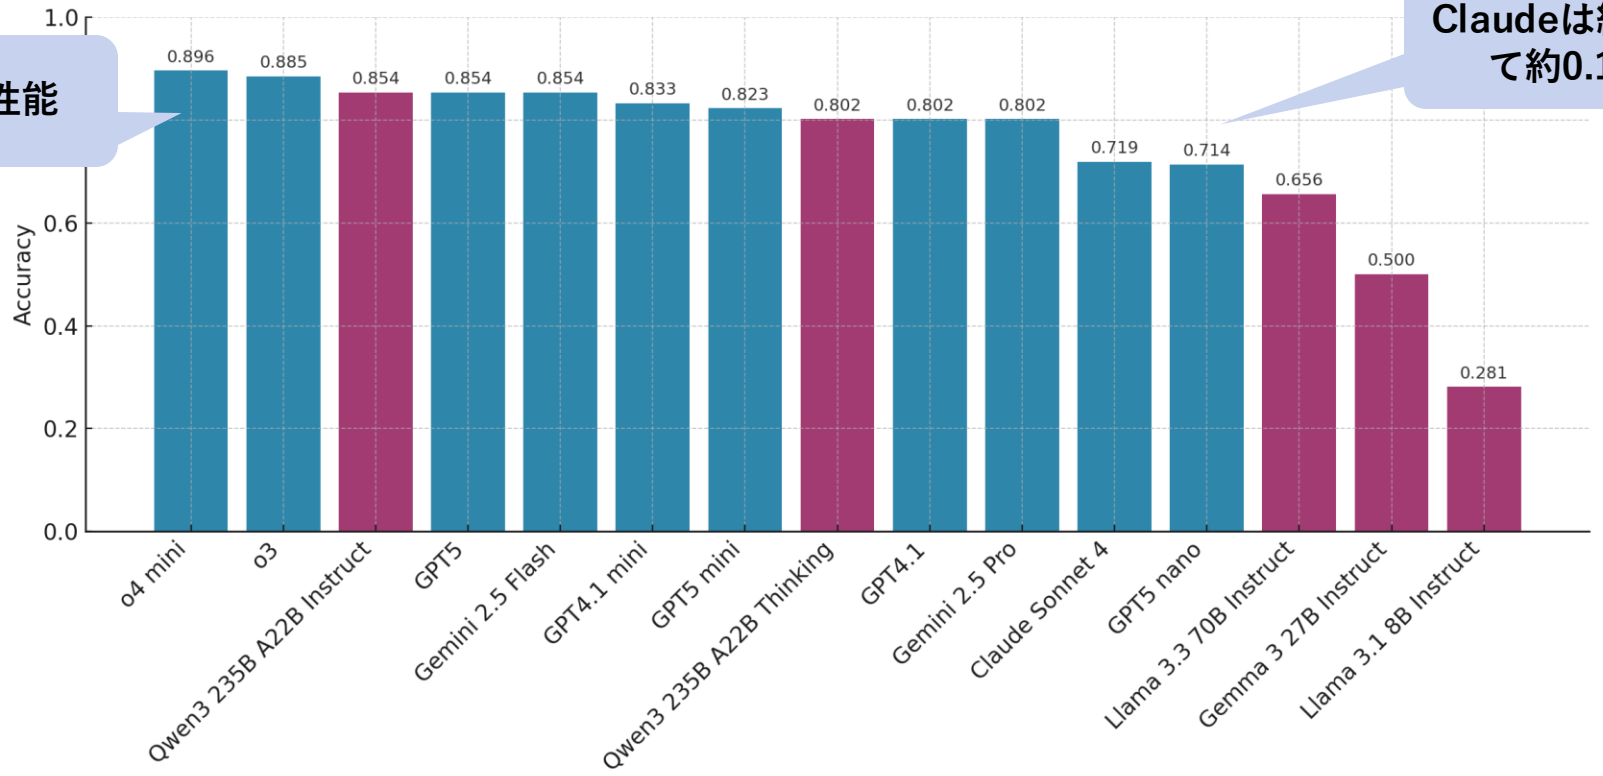

評価結果: 評価カテゴリ別

カテゴリ別に定量化 ⇒ モデル間で各能力の比較が可能に

J-RAGBenchの評価カテゴリ別の評価結果

モデル名	Integration	Reasoning	Logic	Table	Abstention
GPT5	0.833	0.870	0.867	0.839	0.900
GPT5 mini	**0.917**	0.826	0.867	0.774	0.833
GPT5 nano	0.750	0.565	0.733	0.677	0.767
o3	0.833	**0.957**	**0.900**	0.839	0.817
o4 mini	**0.917**	0.913	**0.900**	**0.871**	0.873
GPT 4.1	0.833	0.739	0.800	0.839	0.850
GPT 4.1 mini	**0.917**	0.870	0.800	0.806	0.783
Gemini 2.5 Flash	**0.917**	0.783	0.867	**0.871**	0.783
Gemini 2.5 Pro	0.667	0.870	0.833	0.774	0.800
Claude Sonnet 4	0.750	0.783	0.700	0.677	**0.950**
Llama 3.1 8B Instruct	0.167	0.130	0.367	0.355	0.600
Llama 3.3 70B Instruct	0.750	0.478	0.733	0.677	0.767
Gemma 3 27B Instruct	0.667	0.348	0.567	0.484	0.733
Qwen3 235B A22B Instruct	**0.917**	0.870	0.833	0.839	0.867
Qwen3 235B A22B Thinking	**0.917**	0.826	0.767	0.774	0.900

GPT5: 全体的に好スコア
バランスが良いモデル

o3, o4-mini:
Mainで良好

GPT 4.1 mini:
小型モデルでも比較的良好

Claude: 回答拒否に強み

Qwen 235B:
API提供に肉薄

Index

主要カテゴリ①：情報統合 (Integration)

- ✓ 多くのモデルが他カテゴリと比較して全体的に高いスコアを獲得
- ✓ 小型モデル (GPT4.1 mini, Gemini 2.5 Flash等) が比較的良好なスコア

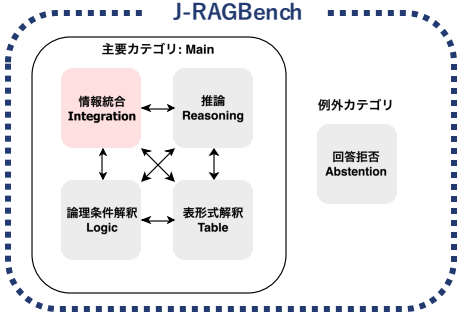

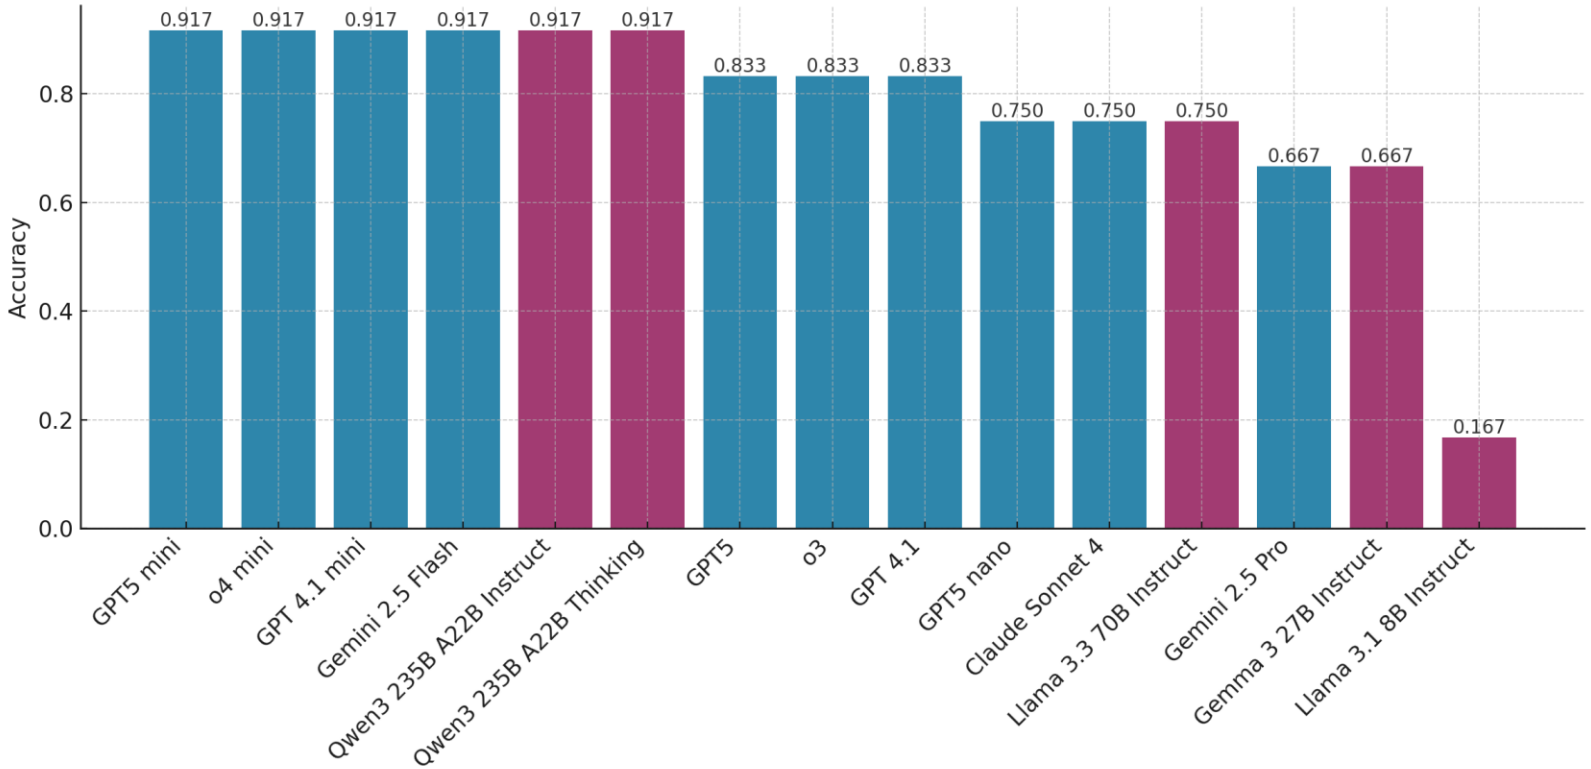

主要カテゴリ①：情報統合 (Integration)

誤答ケース
- 関連文書に直接的な語彙的手がかりが存在しない場合
- 複数の情報が並列して記載 ⇒ 情報の粒度が一部異なる場合

例: 粒度が一部異なる

注釈を加味する必要 &
異なる単位の記載形式

A社、B社、C社の3つの会議室の料金をまとめて。土曜日に4時間利用したい。

【A社 会議室貸出サービス】
基本料金：300円 / 1h
※ 土日祝日の場合は +50円 / 1h となります

【会議室 B社】
基本料金：400円 (1時間あたり)

【C社 レンタル会議室】
基本料金：320円 (1時間あたり)

A社は1,400円(350円 x 4), B社は1,600円(400円x 4), C社は 1,280円(320円 x 4)です

A社は1,200円(300円 x 4), B社は1,600円(400円x 4), C社は 1,280円(320円 x 4)です

※ 説明のためにQA内容を一部簡易化

主要カテゴリ①：情報統合 (Integration)

誤答ケース
- 関連文書に直接的な語彙的手がかりが存在しない場合
- 複数の情報が並列して記載 ⇒ 情報の粒度が一部異なる場合

例: 粒度が一部異なる

注釈を加味する必要 & 異なる単位の記載形式

A社、B社、C社の3つの会議室の料金をまとめて。土曜日に4時間利用したい。

【A社 会議室貸出サービス】
基本料金：300円 / 1h
※ 土日祝日の場合は +50円 / 1h となります

【会議室 B社】
基本料金：400円 (1時間あたり)

【C社 レンタル会議室】
基本料金：320円 (1時間あたり)

A社は1,400円(350円 x 4), B社は1,600円(400円x 4), C社は 1,280円(320円 x 4)です

A社は1,200円(300円 x 4), B社は1,600円(400円x 4), C社は 1,280円(320円 x 4)です

※ 説明のためにQA内容を一部簡易化

⇒ 実運用時では，文書の構造化や正規化といった前処理の重要性を改めて確認

主要カテゴリ②：推論 (Reasoning)

- ✓ o3を筆頭に推論モデルが全体的に高い性能
- ✓ モデルによる性能のばらつきが大きい評価カテゴリ

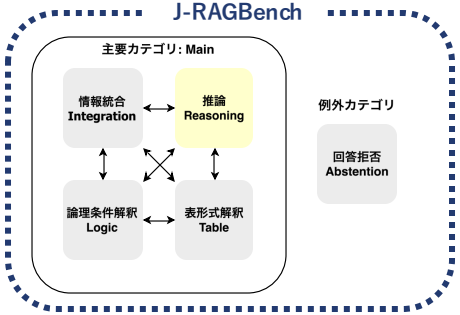

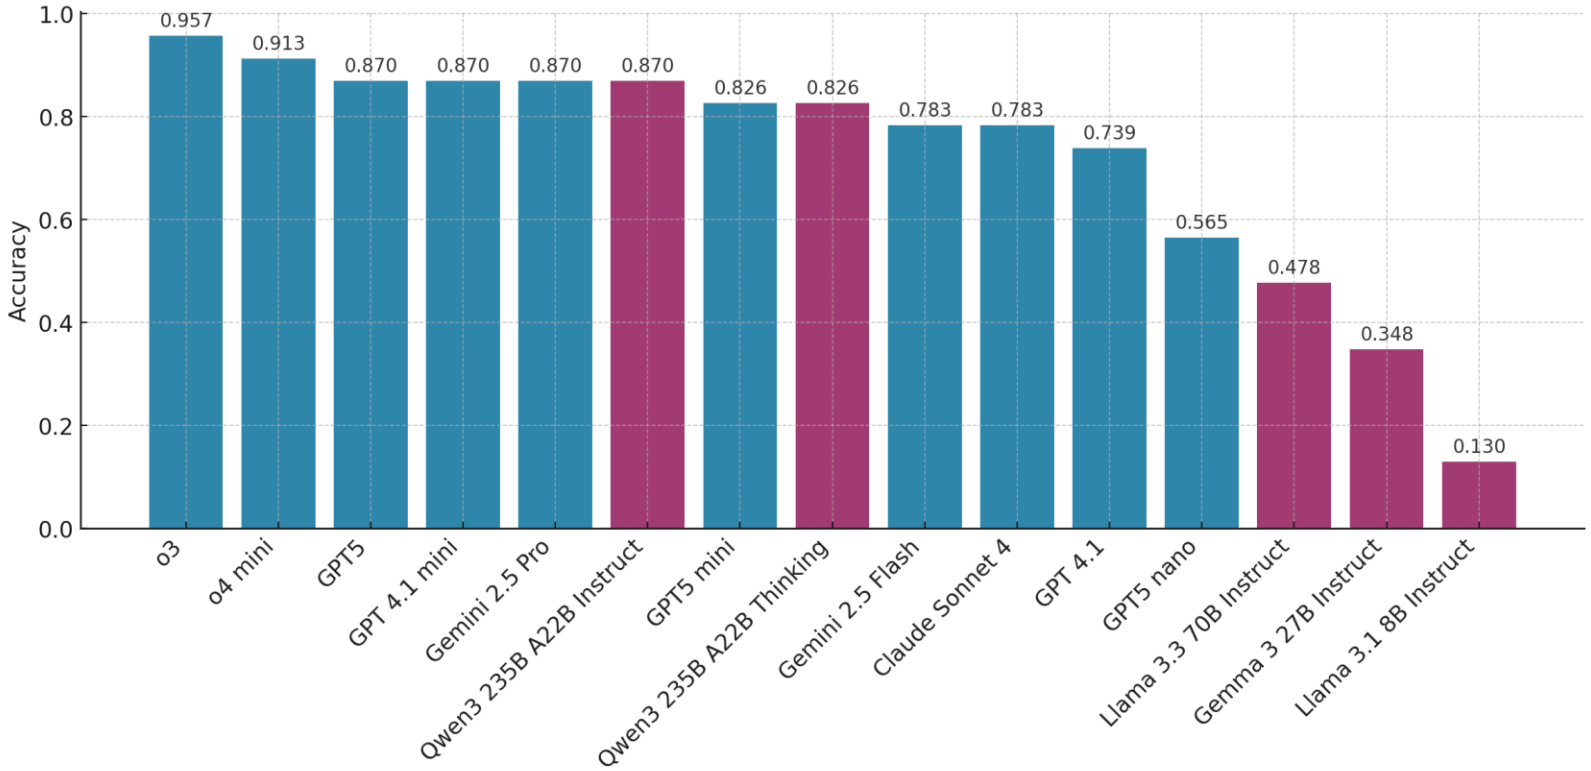

主要カテゴリ②：推論 (Reasoning)

誤答ケース
- 計算ミス：多段階での計算過程における途中または最終生成時
- マルチホップ：中間エンティティに関する直接的な語彙的手がかりが紐づけられない ⇒ 情報不足と判断して回答拒否をする傾向

主要カテゴリ②：推論 (Reasoning)

誤答ケース
- 計算ミス：多段階での計算過程における途中または最終生成時
- マルチホップ：中間エンティティに関する直接的な語彙的手がかりが紐づけられない ⇒ 情報不足と判断して回答拒否をする傾向

評価観点：数値計算

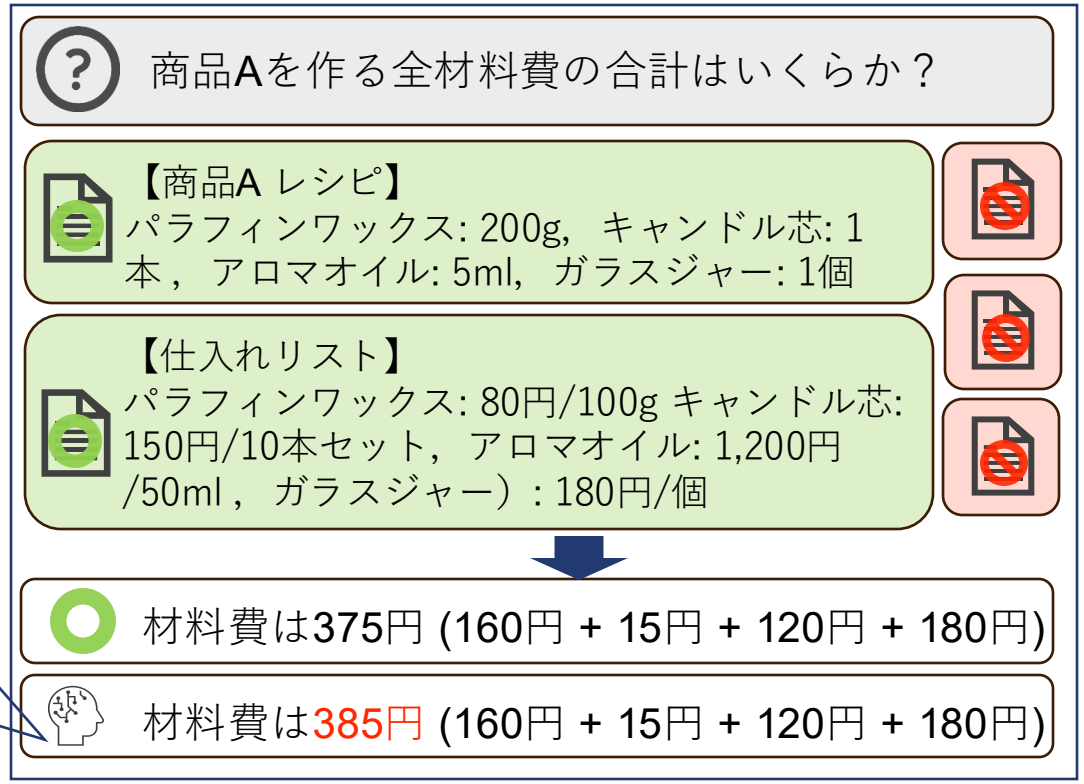

立式までは正解
加算時に計算ミス

以下のモデルでは確認されなかった
- GPT5
- o3
- o4-mini
- Gemini 2.5 Pro

主要カテゴリ②：推論 (Reasoning)

誤答ケース
- 計算ミス：多段階での計算過程における途中または最終生成時
- マルチホップ：中間エンティティに関する直接的な語彙的手がかりが紐づけられない→ 情報不足と判断して回答拒否をする傾向

評価観点：マルチホップ

隠れた中間エンティティ：ブルーイノベーション研究助成

中間エンティティの関係を推論できずに回答拒否

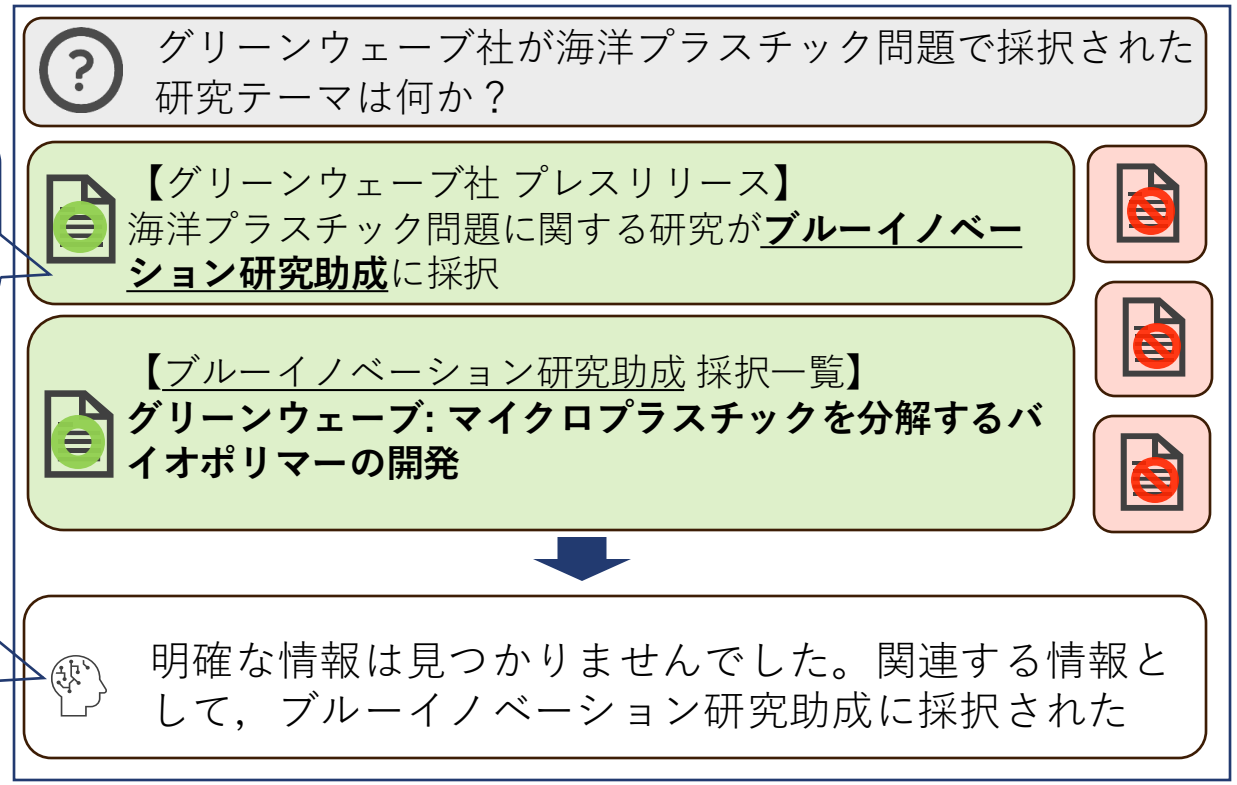

非推論特化モデルの場合に散見

主要カテゴリ③：論理関係の解釈（Logic）

- ✓ 全体的には推論モデルが良い性能を示した
- ✓ 「7,616 百万円 ⇔ 76億1600万円」等の単位変換：
  GPT 4.1等の上位モデルにおいても7.6億円などの誤答を確認

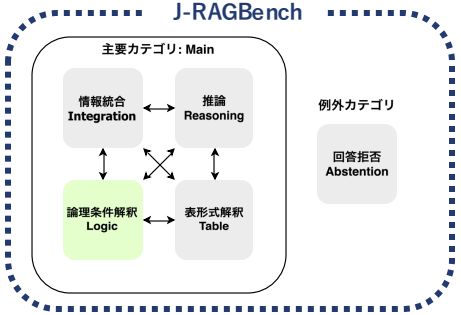

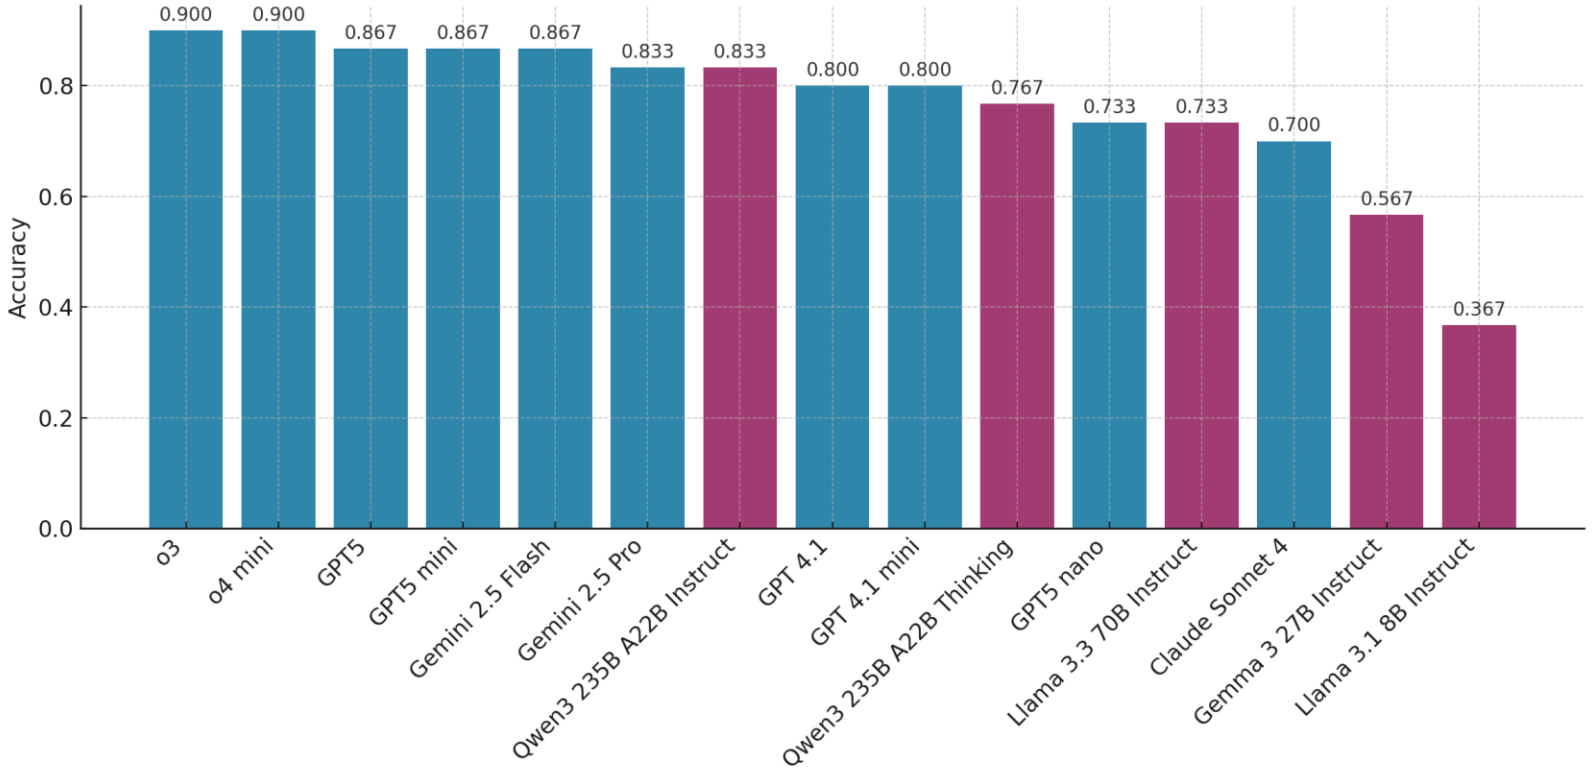

主要カテゴリ③：論理関係の解釈（Logic）

誤答ケース

- 日本語特有の単位変換：

「7,616 百万円 ⇔ 76億1600万円」であるが，7.6億円と回答

評価観点：同義関係の解釈

株式会社統計解析Labの研究支援金収入は何億円ですか？

＜予算計画＞
（単位：百万円）

区分	内容	中期計画予算（平成25～29年度）	平成25年度予算
収入	研究支援金収入	41,339	7,616
収入	受託製表収入	97	22

⋮

単位変換のミス

7.6億円です。

76億16000万円です

主要カテゴリ④：表形式の解釈（Table）

GPT 4.1mini等の小型モデルが比較的良好なスコア

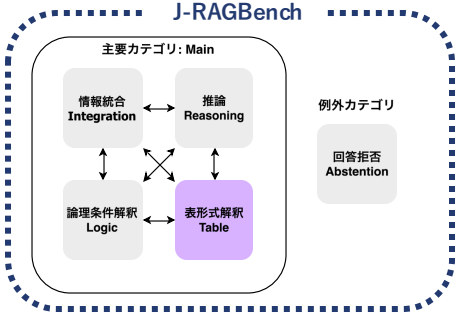

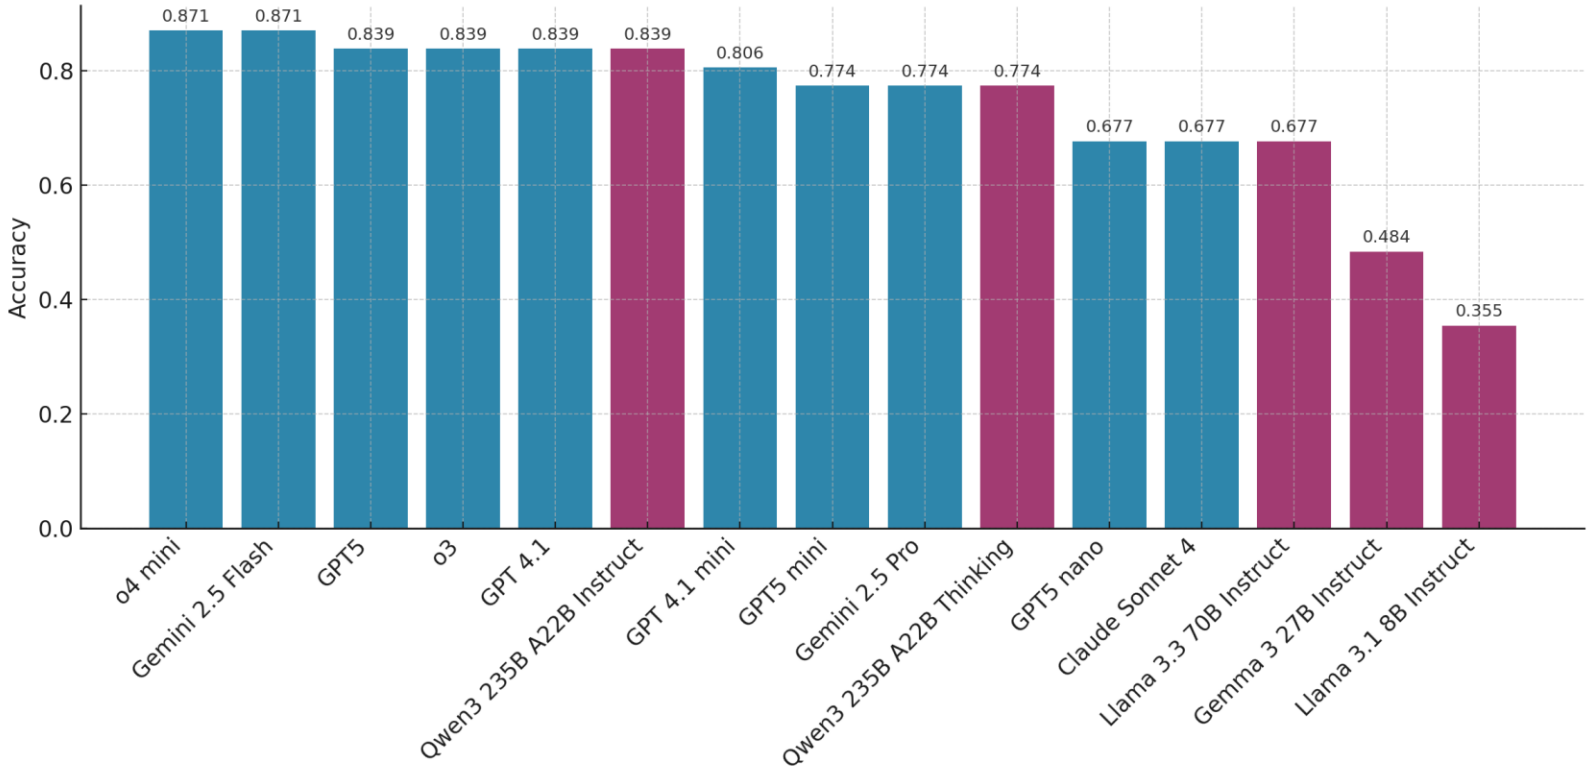

主要カテゴリ④：表形式の解釈（Table）

誤答ケース
- セル結合時の情報抽出
- 大規模な表が複数チャンクに分割

主要カテゴリ④：表形式の解釈（Table）

誤答ケース
- セル結合時の情報抽出
- 大規模な表が複数チャンクに分割

HTML セル結合

表のヘッダー部分がセル結合

情報を特定できずに回答拒否

エコアンドフロンティアの家電部門、IoT部門のQ3の海外利益は？

部門	四半期	売上および利益 (百万円)					
		国内		海外		合計	
		売上	利益	売上	利益	売上	利益
電子機器	Q1	3000	900	2000	600	5000	1500
	Q2	3200	950	2100	650	5300	1600
	Q3	3400	1000	2200	700	5600	1700
	Q4	3600	1050	2300	750	5900	1800
家電	Q1	1800	500	1200	400	3000	900
	Q2	1900	550	1300	450	3200	1000
	Q3	2000	600	1400	500	3400	1100
	Q4	2100	650	1500	550	3600	1200

IoT部門も下に続く

海外利益に関する明確な情報は見つかりませんでした。

主要カテゴリ④：表形式の解釈（Table）

誤答ケース
- セル結合時の情報抽出
- 大規模な表が複数チャンクに分割

評価観点：Markdown

チャンク分割後にヘッダーを挿入して保存

キャッスレス決済に対応している店舗名を列挙して

常慶商店街 店舗ID	店舗名	現金	電子決済	クレジットカード決済	QR決済
T001	灯凪コーヒー舎	○	○	○	○
…					
T025	笹鳴うどん屋	○	○	×	×

常慶商店街 店舗ID	店舗名	現金	電子決済	クレジットカード決済	QR決済
T026	曙ミルクスタンド	○	○	○	○
…					
T050	海鳴レモネード店	○	○	○	×

常慶商店街 店舗ID	店舗名	現金	電子決済	クレジットカード決済	QR決済
T001	灯凪コーヒー舎	○	○	○	○
T002	霧霞ベーカリー	○	×	×	○
T003	翠雨書房	○	○	×	×
T004	朧月雑貨店	○	○	○	×
T005	桔梗ラーメン工房	○	×	○	×
T006	風燈スイーツ堂	○	○	○	○
T007	朱鷺ハーブ茶屋	○	×	○	×
T008	青藍カレー食堂	○	○	×	○
T009	雪渓アウトフィッターズ	○	○	○	×
T010	木漏れ日文具館	○	×	○	○
T011	霜夜キャンドル工房	○	○	×	×
T012	紫苑トーストスタンド	○	○	○	○
T013	葉陰フラワーアトリエ	○	×	×	○
T014	杓葉レコード店	○	○	○	×
T015	銀砂パスタ食堂	○	×	○	○
T016	風待ちブックス	○	○	×	×
T017	蜃気楼スパイス商会	○	○	○	○
T018	露草ジェラート舗	○	×	×	○
T019	白凍ギフトサロン	○	○	○	×
T020	星屑ティーラボ	○	○	×	○
T021	木霊アウトドア商店	○	×	○	×
T022	南天シフォンベイク	○	○	○	○
T023	砂紋ファブリック館	○	×	×	×
T024	月灯り珈琲と本	○	○	×	○
T025	笹鳴うどん屋	○	×	○	×
T026	曙ミルクスタンド	○	○	○	○
T027	海霧マリン雑貨	○	○	×	×
T028	風薫ベーカリーラボ	○	○	○	○
T029	緋色クラフト酒場	○	×	○	○
T030	天泪キャンプギア	○	○	×	×
T031	柳しずく甘味店	○	○	○	○
T032	月白インテリア堂	○	×	×	○
T033	山桐ロースターズ	○	○	○	×
T034	波灯食堂	○	×	○	×
T035	紺碧モバイル茶屋	○	○	×	○
T036	駒鳥バターサンド舎	○	○	○	○
T037	砂灯テキスタイル	○	×	×	×
T038	花霞ソーダバー	○	○	×	○
T039	雪解けパティスリー	○	○	○	×
T040	茜空ブーランジュ	○	×	○	○
T041	霧雨リビング用品店	○	○	×	×
T042	音羽ペンと紙	○	○	○	○
T043	露原スープ食堂	○	×	×	○
T044	白楓ワークス	○	○	○	×
T045	風紋せんべい処	○	×	○	×
T046	月雫ティールーム	○	○	○	○
T047	朔風プラントショップ	○	○	×	×
T048	瑠璃バウム工房	○	○	○	○
T049	木庵レザークラフト	○	×	×	○
T050	海鳴レモネード店	○	○	○	×
T051	ひより和菓子庵	○	×	○	×
T052	霄ノ湯サロン	○	○	×	○
T053	石畳キッチン	○	○	○	○
T054	鴇色パン研究所	○	×	×	×
T055	霜花ノートと万年筆	○	○	○	×
T056	真砂スムージー舎	○	○	×	○
T057	灯台クラフトビール	○	×	○	○
T058	漣ブティック	○	○	×	×
T059	銀の林古道具店	○	○	○	○
T060	茶褐カフェと焙煎	○	×	×	○
T061	霞立つラーメン横丁	○	○	○	×
T062	雨音フルーツ工房	○	○	×	○
T063	薄荷トートと雑貨	○	×	○	×
T064	月代サンドベイク	○	○	○	○
T065	霧笛オーブンスタジオ	○	○	×	×
T066	銅葉パスタ工房	○	○	○	○
T067	鳶肥デリカテッセン	○	×	×	○
T068	雨燕アウトドア喫茶	○	○	○	×
T069	朧霞ステーショナリー	○	×	○	○
T070	白露シリアルバー	○	○	×	×

例外カテゴリ：回答拒否（Abstention）

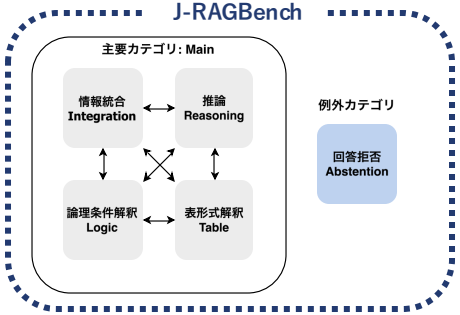

関連する尤もらしい知識の補完による誤答を確認：知識の捏造

Claude Sonnet 4が最も高いスコア：知識の捏造は0件

一部の推論モデル（o3やGemini2.5 Pro等）がやや低いスコアの傾向

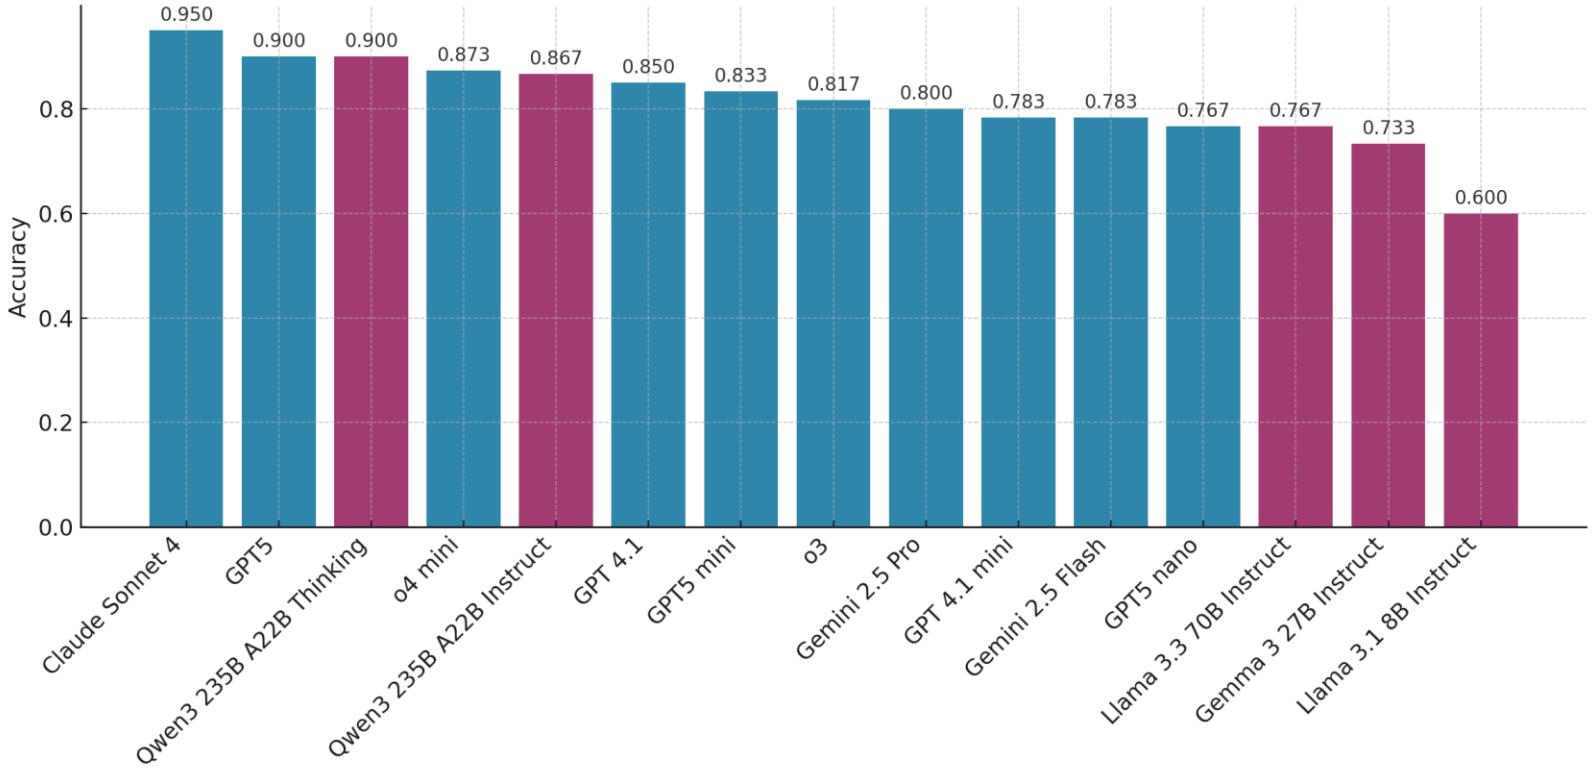

例外カテゴリ：回答拒否（Abstention）

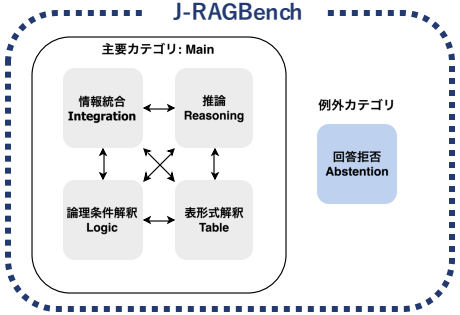

Claude Sonnet 4

- 回答拒否能力が他モデルと比較して高い
- **回答可能なMainカテゴリのQAに対しても回答拒否をして誤答する傾向**

⇒ 回答拒否の閾値設定が保守的である可能性を示唆

例外カテゴリ：回答拒否（Abstention）

誤答ケース

- 根拠の捏造：根拠は含まれないが，関連するキーワードに反応して誤った事実を回答
- LLMの事前知識に基づくハルシネーション：ユーザの曖昧な質問等に対して関連文書が存在しない場合に事前知識に基づく回答を提示

例外カテゴリ：回答拒否（Abstention）

誤答ケース

- 根拠の捏造：根拠は含まれないが，関連するキーワードに反応して誤った事実を回答
- LLMの事前知識に基づくハルシネーション：ユーザの曖昧な質問等に対して関連文書が存在しない場合に事前知識に基づく回答を提示

評価観点：根拠不足

北祭京シェアサイクルを4時間当日利用した場合の料金はいくらですか？

【掛橋市 シェアサイクル】

区分	当日利用（24時間）	定期利用（1か月）
普通自転車	210円	2,100円
電動アシスト自転車	340円	4,380円

北祭京市シェアサイクルの当日利用料金は1日あたり210円であり，
4時間の場合も210円で利用可能です

入力コンテキストに北祭京市や4時間利用の場合についての情報は存在しない

例外カテゴリ：回答拒否（Abstention）

誤答ケース

- 根拠の捏造：根拠は含まれないが，関連するキーワードに反応して誤った事実を回答
- LLMの事前知識に基づくハルシネーション：ユーザの曖昧な質問等に対して関連文書が存在しない場合に事前知識に基づく回答を提示

評価観点：根拠不足

グリーンウェーブ社が2024年に海洋プラスチック問題で正式に採択された主要研究テーマは何？

波力利用スタートアップ「グリーンウェーブ社」および豪州エネ庁は共同で、生分解性漁具パイロットプロジェクトを 2024 年 9 月からタスマン海で開始すると発表した。

UNEP の 2024 年報告書によれば、一次マイクロプラスチック（樹脂ペレット・合成繊維など）が全体流出量の 31 % を占め、二次マイクロプラスチック（波浪摩耗由来）が 69 % と推計され

本件について回答できる情報はありません。ただし、関連する取り組みとしては、海洋分解性PLAブレンド樹脂の開発にも取り組んでいる

「海洋分解性PLAブレンド樹脂」という単語は入力コンテキストに存在しない

例外カテゴリ：回答拒否（Abstention）

誤答ケース

- 根拠の捏造：根拠は含まれないが，関連するキーワードに反応して誤った事実を回答
- LLMの事前知識に基づくハルシネーション：ユーザの曖昧な質問等に対して関連文書が存在しない場合に事前知識に基づく回答を提示

評価観点：根拠の矛盾

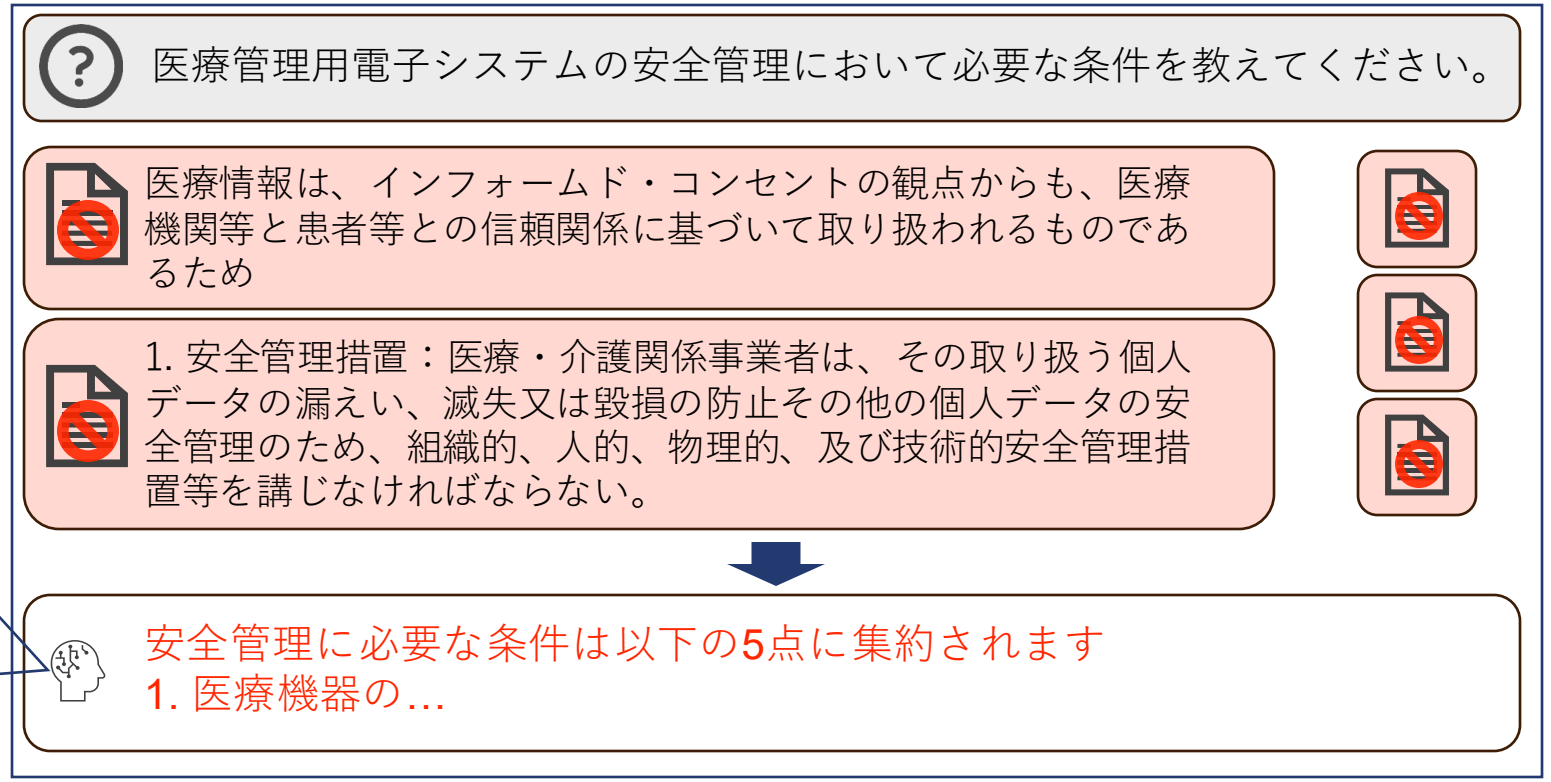

入力コンテキストにこの情報は含まれておらずLLMの事前知識に基づいて回答をしている

Index

まとめ

- 日本語RAG の Generator 評価のための **J-RAGBench** を構築・公開
  - ✓ 実運用時の課題から評価範囲を5つのカテゴリに体系化
  - ✓ 評価観点の組み合わせパターンを網羅
- 各種LLM（API提供，オープンウェイト）の評価実験
  - ✓ 観点別のモデル間性能を定量的に比較可能
  - ✓ 用途に応じたモデル選択の重要性を示唆
  - → 実運用時のLLM選定・RAG特化LLM構築の指標

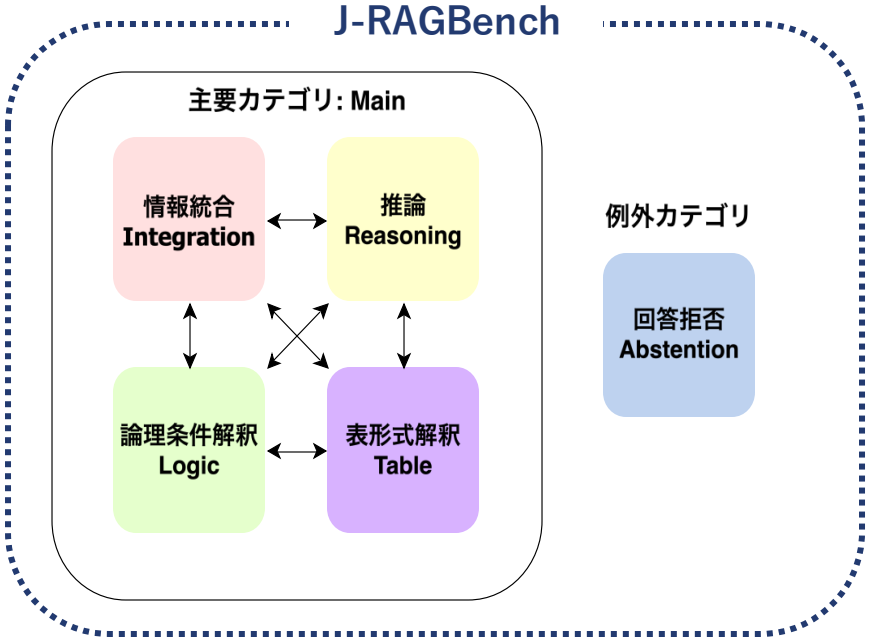

今後の展望

- 問題数の拡充等の定期アップデートによる
  コミュニティ貢献の
- 多言語化による適用範囲の拡大
- Agentic RAG等への評価ベンチマークの拡張


neoAI