

技術観点の自動検出による技術動向マップ自動生成

蜂須賀笙太 任晶 福田悟志 難波英嗣 庄司裕子
中央大学大学院理工学研究科

概要

本研究は、技術分野における動向把握の効率化と精度向上を目的としている。従来の技術動向分析手法は、専門家の評価に依存し、高コストであるとともに迅速性や説明可能性に課題を抱えていた。これらの課題を解決するために、本研究では大規模言語モデル (LLM) を活用し、技術観点の自動検出による技術動向マップの構築手法を提案する。本手法により、膨大な技術情報を効率的かつ体系的に整理し、的確な技術動向の分析とその活用を支援する基盤を提供することが可能となる。

1 はじめに

技術分野における動向把握の効率化や精度向上は、研究開発戦略の立案において極めて重要である。しかし、従来の手法には以下の課題が存在する。一つは迅速性の問題であり、各分野の専門家による技術シーズの重要度評価は、時間や費用の面で大きなコストがかかるうえ、一度評価が行われても、研究・開発スピードが速い分野ではその有効性が短期間で失われる可能性がある。このため、評価プロセスの自動化または半自動化が求められる。ただし、自動化が進む中でも、専門家が必要に応じて介入できる柔軟性を確保する必要がある。また、もう一つの課題は説明可能性である。重要技術の優先順位を提示するだけでなく、なぜその順位に至ったのか、具体的な根拠を示すことが必要である。この点は、研究機関や企業が結果を納得し、活用するうえで特に重要である。

本研究では、これらの課題に対応するために、技術動向マップの自動生成を目指す。具体的には、大規模言語モデル (LLM) を活用して、特定の技術分野における特徴的な要素や課題を自動的に検出し、それらを基にした技術動向の分析を行う。これにより、従来の手法では対応しきれなかった広範囲かつ迅速な分析が可能となり、専門家による介入の余地を確保しつつ、根拠の明確な結果を提示することができる。

なお、特許庁が実施する「特許出願技術動向調査」は、本研究が取り組む方法論の一例として位置付けられる。毎年、特許庁は注目度の高い技術分野を10個程度抜粋し、特許情報を精査・分析している。この調査では、関連する特許や論文を詳細に分析し、先端技術分野の出願状況や研究開発の方向性を明らかにすることで、日本の産業が優位にある分野や劣位にある分野についての分析等が可能となる。

この特許出願技術動向調査の一環として技術観点 (技術区分) の調査・付与が行われる。技術観点とは「機械翻訳」や「ドローン」などの各分野の課題や用途などの各要素のことである。表1は、令和2年度に実施された機械翻訳分野の調査において作成された技術観点軸の一部を示したものである。この観点軸を基に、特許に対して技術観点を付与し、技術動向マップを構築することで、各国の技術的な強みや日本の研究開発の方向性を明らかにすることが可能となる。本研究では、大規模言語モデル (LLM) を活用することにより、このような技術観点を自動的に検出する手法を提案する。

表1 令和2年度特許出願技術動向調査
「機械翻訳」における技術観点軸の一部抜粋

第1階層	第2階層	第3階層
統計的機械翻訳	モデル構築	翻訳モデル
		言語モデル
ニューラル 機械翻訳	モデル構築	ビーム探索
		埋め込み
		DL

2 関連研究

2.1 技術用語の抽出

近藤[6]らは、特許や論文の構造に着目し、構造解析を用いて要素技術を抽出する手法を提案している。また、近藤らに加えて、Yeら[9]も特許の構造を活用し、技術用語の抽出を試みている。これらの手法はいずれも教師あり学習を用いており、特定の分野における技術情報の抽出において一定の成果を上げている。一方で、Francescoら[2][3]は教師なし学習

を活用した技術用語の抽出方法を提案し、ラベル付けの必要がない手法の有効性を示している。

近年、大規模言語モデル (LLM) の登場により、LLM を活用した用語抽出にも注目が集まっている。Doi ら[1]は、LLM の文脈理解能力を活用し、より正確なトピック推定を可能にする手法を提案している。また、LLM の入力サイズ制限への対応として、「Parallel prompting」および「Sequential prompting」と呼ばれる手法を提案し、その有効性を実証している。

本研究では、LLM を活用することで、特許や論文から技術観点を抽出する新たな手法を提案する。本手法は、単に技術用語を抽出するだけでなく、対象分野における課題や用途を体系的に整理することを目的としている。これにより、特許や学術論文をより深く分析し、技術動向を的確に把握するための基盤を構築する。

2.2 技術動向マップの構築

近藤ら[6]は、特許や論文の構造解析および機械学習技術を活用し、要素技術とその効果を示す表現を自動抽出する手法を提案している。この情報を基に、特定技術分野の進展や関連性を視覚化する技術動向マップを自動生成している。また、Nakamitsu ら[10]は、米国特許に「field」「problem」「solution」「effect」の構造タグを自動付与し、これらを基にクラスタリングで特許マップを構築している。特に、「solution」のクラスタリング結果が特許出願技術動向調査の分析軸に近い結果を示している。一方、クラスタの説明性が低い点が課題として挙げられる。

また、Singh ら[12]は、増加する科学論文から情報を抽出し、リーダーボードを自動生成することで、情報過多への対処や先行研究の比較を効率化する手法を提案している。本研究の観点軸生成手法とリーダーボード生成には、膨大なデータから有用な情報を体系的に整理し、視覚化を通じて意思決定や研究支援を行うという共通点がある。

本研究では、観点軸を自動生成する手法を提案し、これを用いて技術動向マップの作成を目的とする。観点軸の自動生成により、技術情報の体系的な整理を効率化し、技術動向の把握を補助する。

3 提案手法

技術動向マップの自動生成は、(1)技術観点の自動検出と(2)特許の技術観点への自動分類によって実

現される。それぞれの手順については、3.1 節および 3.2 節で詳述する。

3.1 技術観点の自動検出

2 節で述べたように、技術用語の抽出に関しては、これまで多くの手法が提案されており、従来の方でも一定の精度を実現できる可能性がある。しかし、本研究の目的は単なる技術用語の抽出にとどまらず、対象技術分野から技術観点を抽出し、技術分野の課題や用途などを体系的に整理することにある。

本研究では、大規模言語モデル (LLM) を活用して技術観点軸を自動生成する手法を提案する。具体的には、図 1 に示すように、複数の特許をプロンプトとして LLM に入力し、それを基に技術観点を階層構造で抽出する。LLM への入力プロンプトは、図 2 に示すように 4 つの段落から構成されている。また、多言語に対応する LLM を用いることで、世界中の文書を分析可能となる。最終的に得られる出力は CSV 形式で提供され、各要素が技術観点として整理される。

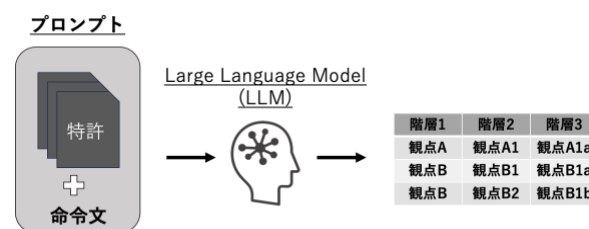


図 1 技術観点の検出方法

```
[Data on Perspective Axes]
<input patent abstracts>
[Request]
Please construct a perspective axis for "<theme>".
[Summary Format]
* Do not include "Others".
...
[Output Format]
* Output in CSV table format.
...
```

図 2 観点軸生成のプロンプト例

LLM の Fine-tuning

LLM は膨大なデータで事前学習されており、多様なタスクを高精度に実行する能力を持っている。しかし、技術観点の抽出や要約といった特定のタスクに関しては、事前学習だけでは十分な性能を発揮できない場合がある。そこで、本研究では、LLM を

Fine-tuning することによって、観点軸の生成における精度向上を試みる。

Fine-tuning には、特許庁が採用している F タームを利用する。F タームとは、特許を体系的に分類するために設定された日本特許独自の分類体系であり、技術の課題や用途、構成要素などに基づいて整理されている。Fine-tuning では、特に「目的」や「用途」に関する F タームを基に学習を行い、これらの情報をより正確に抽出し、効率的にまとめることを目的とする。

LLM の入力サイズ制約への対応

技術動向マップを生成する際には、対象となる分野の特許や論文といった膨大なデータを分析する必要がある。しかし、これらのデータを大規模に分析する過程で、LLM には入力サイズの制約があるため、一度にすべての文書を処理することが困難であるという課題が生じる。

この課題を解決するために、本研究では Tomoki Doi ら[1]が提案した「Parallel prompting」と「Sequential prompting」の手法を採用する。Parallel Prompting では、大量のデータを複数のサブセットに分割し、サブセットごとに独立して観点軸を生成する。一方、Sequential Prompting では、最初のサブセットで生成した観点軸を基に次のサブセットのデータを用いて観点軸を順次更新する。この方法により、新たなデータの追加や変更にも柔軟に対応しながら、観点軸の精度と網羅性を向上させることが可能となる。

3.2 特許の技術観点への自動分類

3.1 節で述べた手法により検出された観点軸に特許を自動分類する際には、大量のラベル付きデータを用いた機械学習が困難なため、zero-shot あるいは few-shot 学習を活用する必要がある。本節では、それぞれの手法を用いた分類方法について説明する。

zero-shot 学習による分類

zero-shot 学習では、LLM（大規模言語モデル）に以下の情報を入力し、特許が特定の観点軸に属するかを判定させる：

1. 観点軸リスト（観点軸全体をリスト化したもの）
2. 特許の発明名称と概要（1 件分）
3. 対象とする観点軸（観点軸リストから 1 つを選択）

具体的なプロンプトの例を図 3 に示す。この図では、<トピック>を「CO2 固定化技術・有効利用」な

どの具体的な文字列に、<観点軸リスト>、<発明の名称>、<概要>、<観点>をそれぞれ前述の情報(1~3)に置き換える。

[データ]

以下は<トピック>に関する特許の内容です。

<発明の名称>

<概要>

次に、以下は<トピック>に関する技術観点軸です。1~5 階層目までの観点軸が、csv 形式で記述されています。

<観点軸リスト>

[依頼]

特許が以下の技術分析軸に属する場合は 1 を、属さない場合は 0 を返してください。分類の根拠に関する説明は必要ありません。

<観点>

図 3 特許分類のプロンプト例

few-shot 学習による分類

Few-shot 学習では、著者らが F タームと呼ばれる特許分類体系を用いて事前に BERT モデルを学習させている[5]。このモデルを利用することで、新しいカテゴリに対しても Few-shot 学習を通じた特許分類が可能となる。この手法を応用し、技術観点軸への特許分類を実現する。

4 実験

本節では、3.2 節で述べた特許の技術観点への自動分類に関する実験結果を報告する。なお、3.1 節の技術観点の自動検出については次節で詳述する。

4.1 実験方法

データ：以下の特許出願技術動向調査報告書を実験に使用した：

- 「CO2 固定化・有効利用技術」（平成 29 年度）
- 「樹脂素材と異種素材との接合技術」（平成 30 年度）

それぞれの報告書から、人手で作成された技術観点軸を選定し、前者は 25 軸、後者は 20 軸を用いた。各観点軸に対し、以下のようにデータを分割した：

- 訓練用データ：150 件
- 検証用データ：50 件
- 評価用データ：50 件

合計で 11,250 件の特許概要を使用した。なお、すべてのデータセット（訓練用、検証用、評価用）において、正例と負例の割合はそれぞれ 50%とした。

評価尺度：再現率、精度、F1 値で評価した。

比較手法: 5 種類の LLM(GPT-4-Turbo-1106、GPT-4-Turbo-2024-04-09、GPT-4o、o1-preview、Gemini)と BERT(fewshot)[5]を比較した。

4.2 実験結果

実験結果を表 2 に示す。

主な結果と考察

- GPT-4-Turbo: 2 つの GPT-4-Turbo モデルは非常に高い精度を達成したが、再現率が極端に低い結果となった。この低い再現率は、正例の多様性を十分に捉えられないことを示唆している。
- Gemini: Gemini は最も高い再現率を示したが、精度は低く、実用性に欠けると考えられる。評価用データの半数が正例であることを考慮すると、Gemini がすべての特許を分析軸に属すると判断した場合 (精度 0.5、再現率 1.0) と比較してわずかに優れているにすぎない。
- BERT: BERT は比較手法の中で最も高い F1 値を示し、精度と再現率のバランスが取れた手法であることが分かった。

最低な分類手法の提案

今回の実験結果から、単一の手法だけでは最良の特許分類を実現するのは難しいと考えられる。最適な方法として、以下の手順を提案する：

1. GPT-4-Turbo-1106 で初期分類を行う。
2. GPT-4-Turbo-1106 で分類できなかった特許については、BERT を用いて再分類する。

このアプローチにより、精度と再現率のトレードオフを解消し、より効果的な分類が実現できると考えられる。

表 2 zero-shot および few-shot 学習による分類結果

比較手法	精度	再現率	F1
GPT-4-Turbo-1106	0.871	0.271	0.414
GPT-4-Turbo-2024-04-09	0.851	0.274	0.414
GPT-4o	0.636	0.740	0.684
o1-preview	0.736	0.637	0.683
Gemini	0.584	0.781	0.668
BERT(fewshot)[5]	0.665	0.769	0.713

5 技術観点の自動検出に関する考察

本節では、OpenAI の GPT-4o および GPT-4o mini を用いた Fine-tuning の結果と、それぞれのモデル特性について考察する。Fine-tuning には、F タームのうち「目的」に分類される 206 個の観点を正解デー

タとして使用した。各観点に対して 100 件の特許から「発明が解決しようとする課題」の文章を入力データとして用い、モデルを構築した。

GPT-4o および GPT-4o mini の特徴

GPT-4o mini: GPT-4o mini は、一般的な用語を用いた観点軸を生成する傾向がある。そのため、広範な技術分野に共通するテーマを網羅する能力に優れる。一方で、以下の課題が確認された：

- 出力の詳細性が GPT-4o に比べて控えめであり、課題を深掘りする能力に限界がある。
- 観点軸の構造に繰り返しや不要な階層が含まれる場合が多く、効率的な整理や階層構造の最適化が求められる。

GPT-4o: GPT-4o は、より具体的な課題を捉える能力が特徴的である。効率改善、純度向上、資源回収など、技術開発に直結する具体的な観点を多く含むため、課題解決の方向性を明確に示すことが可能である。

モデルの使い分け: 両モデルは、それぞれの特性に応じた使い分けが可能である。

- 広範な全体像の把握: GPT-4o mini が適している。
- 具体的な技術課題の深掘り: GPT-4o が適している。

Fine-tuning の効果

GPT-4o mini: Fine-tuning を適用した GPT-4o mini では、観点軸の生成に一定の改善が見られた。特に、F タームを学習したことで分野特有の観点を抽出する能力が向上したと考えられる。この改善は、F タームが広範な技術分野をカバーしつつ抽象的な分類項目を含む特性によるものである。

GPT-4o: 一方、GPT-4o では Fine-tuning の影響がほとんど見られず、出力される観点軸に大きな変化は確認されなかった。この結果は、GPT-4o が初期段階で既に高度な具体性を備えていることを示唆している。

6 結論

本研究では、LLM を活用した技術観点軸の自動生成手法を提案し、技術動向マップ構築を行った。Fine-tuning を適用した GPT-4o mini では分野特有の観点を抽出でき、一定の改善が確認された。一方で、検出結果の定量評価が行われておらず、具体的な性能の測定が今後の課題として挙げられる。

謝辞

特許分類に関する議論で貴重なご助言を賜りました丸崎恒司様に、心より感謝申し上げます。

参考文献

1. Tomoki Doi, Masaru Isonuma, and Hitomi Yanaka. Topic Modeling for Short Texts with Large Language Models. Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics, 2024, pp. 21-33
2. Francesco Fusco, Peter Staar, and Diego Antognini. Unsupervised Term Extraction for Highly Technical Domains. Proceedings of EMNLP 2022 Industry Track, pp. 1-8, 2022
3. Francesco Fusco and Diego Antognini. Extracting Text Representations for Terms and Phrases in Technical Domains. Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics, Vol 5, pp. 61-70, 2023
4. 福田悟志, 難波英嗣, 竹澤 寿幸, 橋田 浩一, 用語の属性を考慮した上位, 下位概念辞書の構築. 言語処理学会 第 20 回年次大会, 2014
5. Shota Hachisuka, Yuta Nakada, Hidetsugu Nanba, and Satoshi Fukuda. Japanese Patent Classification Using Few-shot Learning. Proceedings of the 14th International Conference on Advanced Applied Informatics (IIAI AAI 2023), 2023
6. 近藤 友樹 難波 英嗣 竹澤 寿幸, 論文と特許からの技術動向マップの自動構築. 言語処理学会 第 20 回年次大会, 2010
7. Aobo Kong, Shiwang Zhao, Hao Chen, Qicheng Li, Yong Qin, Ruiqi Sun, and Xiaoyan Bai. PromptRank: Unsupervised Keyphrase Extraction Using Prompt. Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics, Vol 1, pp. 9788-9801, 2023
8. Ye Liu, Han Wu, Zhenya Huang, Hao Wang, Jianhui Ma, Qi Liu, Enhong Chen and, Hanqing Tao, Ke Rui. Technical Phrase Extraction for Patent Mining: A Multi-level Approach. IEEE International Conference on Data Mining (ICDM), 2020
9. Ye Liu, Han Wu, Zhenya Huang, Hao Wang, Yuting Ning, Jianhui Ma, Qi Liu, and Enhong Chen. TechPat: Technical Phrase Extraction for Patent Mining. ACM Transactions on Knowledge Discovery from Data, Vol 17, Issue 9, 2023, pp. 1-31
10. Jun Nakamitsu, Satoshi Fukuda, and Hidetsugu Nanba. Generating a Technical Trend Map by Analyzing the Structure of U.S. Patents Using Patent Families. Information Engineering Express, Vol 10, Issue 2, 2024
11. 難波英嗣, 乾孝司, 岩山真, 櫻井孝, 橋田浩一, 藤井敦. 特許分類コード体系に基づくオントロジーの構築 情報分野におけるケーススタディー. 言語処理学会 第 21 回年次大会, 2015
12. Shruti Singh, Shoaib Alam, Husain Malwat, and Mayank Singh, LEGOBENCH: Scientific Leaderboard Generation Benchmark. Findings of the Association for Computational Linguistics: EMNLP, pp. 14598-14613, 2024
13. 徳永匡臣, 岡田智靖. RAG の連結方式および自動評価指標の定量評価. 言語処理学会 第 30 回年次大会, 2024

A 検出された観点軸

「非アルコール性飲料」の「目的」に関して検出された観点軸を以下に示す。

表 3 観点軸：GPT-4o mini

階層 1	階層 2	階層 3	階層 4
健康上の利点	ミネラル吸収	カルシウムとマグネシウム	カルシウムとマグネシウムの吸収促進
健康上の利点	ミネラル吸収	一般的なミネラルサポート	健康のためのミネラル
健康上の利点	抗酸化特性	抗酸化飲料	抗酸化成分
健康上の利点	血糖管理	糖尿病予防	血糖値安定化成分
風味改善	より良い風味	風味を隠す成分	天然風味増強剤
風味改善	香りと食感	食感安定剤	口当たり向上成分
機能性成分	食物繊維	体重管理	食欲抑制成分
機能性成分	プロバイオティクス	腸内健康	消化サポート成分
機能性成分	アミノ酸	筋肉回復	運動後の飲料成分
利便性	簡単な準備	迅速な溶解	飲みやすいフォーマット
利便性	長期保存性	保管中の安定性	包装の革新性

表 4 観点軸：GPT-4o mini (Fine-tuning)

階層 1	階層 2
液体または固体状態の変化	物理的安定性
液体または固体状態の変化	糖類（甘味料）の添加
液体または固体状態の変化	炭酸化
フレーバー修飾剤の調合	フレーバー原料の調合
フレーバー修飾剤の調合	フレーバーの改善
ダイエット	
再水和	
アルコール代謝	

表 5 観点軸：GPT-4o

階層 1	階層 2
健康促進	栄養バランス
健康促進	免疫力向上

健康促進	抗酸化特性
健康促進	病気予防
健康促進	代謝サポート
感覚改善	風味の向上
感覚改善	食感の向上
保存と安定性	長期安定性
保存と安定性	色の保持
保存と安定性	風味の保持
機能性の追加	電解質補給
機能性の追加	エネルギー回復
機能性の追加	疲労回復
生産と構成	持続可能な素材
生産と構成	プロセスの簡素化
生産と構成	コスト削減
特定の利点	体重管理
特定の利点	糖尿病管理
特定の利点	関節の健康

表 6 観点軸：GPT-4o (Fine-tuning)

階層 1	階層 2	階層 3
味覚または香り	苦味の除去	
保存性	熱安定性	
保存性	光安定性	
良好な溶解性	良好な分散性	
食事	低カロリーダイエットまたは	低脂肪ダイエット
食事	低カロリーダイエットまたは	低カロリーダイエット
食事	便秘防止	
組み合わせ	消化器官	臓器
組み合わせ	消化器官	ビタミン
組み合わせ	食品への添加	システム
食品解決	食品の官能検査の評価	
栄養バランスの改善	ビタミン豊富	
身体的健康資源	免疫力向上	病気予防
身体的健康資源	免疫力向上	予防
身体的健康資源または食品に使用	抗酸化作用またはフリーラジカル活性	
乳幼児または高齢者向け	母乳またはミルクを飲むことを促進	