

要約

特許情報は、今日に至るまでの発明を保存したデータベースのようなものであり、様々な発明が保管されている。これらを活用することで、経営戦略や技術の進歩など多岐にわたり、社会に貢献ができる。現状の特許プラットフォームでは、特許全体をビッグデータとして分析を行いたい場合には適しているとはいえない。また、最近の社会変化に対応していくためには多面的な視点から経営戦略を立てることが必要である。その中で、積極的に知的財産情報を活用するIPランドスケープが有効である。

キーワード：自然言語処理、知的財産戦略、IPランドスケープ、特許情報処理、テキストマイニング

1 はじめに

近年、コロナウィルスの影響やグローバル化、インターネット技術やAI、IoT等のデジタル技術の進展、顧客のニーズの多様化や社会環境などの急速な変化など、さまざまな要素が絡みあうことにより、将来を予測することが難しくなっている。急激な変化と不確実性が高まる社会に対応するためには、企業が保持しているコア技術を強化して差別化を行い、優位性を確立することが重要である。また多角的な視点から経営戦略を策定することが不可欠である[1]。

これらの変化は、企業にとってチャレンジへの機会となっており、IPランドスケープでは、新しいビジネスを始めようとする企業が自社の技術を活用して新しい市場に参入することを支援することができる。本研究では莫大な特許情報を整理し、可視化を行うことで、新たな市場・用途・商品・サービスの探索・提案などの支援を行う。

— 2 知的財産戦略と特許情報処理 —

2.1 知的財産戦略とIPランドスケープ

知的財産戦略（知財戦略）とは、企業が知的財産を活用、分析を行いそれらを経営戦略の一部として取り入れることを指す。知財戦略は経営戦略と密接に関係しており、企業全体の戦略において各部飲んや機能の方向性を決定する重要な役割を果たしている。

これらの知財戦略は日本においては特許などのIntellectual Property：IPと景観や風景を意味するLandscapeを組み合わせた造語でIPランドスケープと呼ぶことが多い[図1参照]。特許庁の調査によれば、IPランドスケープが必要であると回答した者は約8割であったのに対し、IPランドスケープを十分に実施できていると回答したものは約1割であった[2]。現在、必要性は理解しているがまだ実施に至っている企業が少ないという状態である。

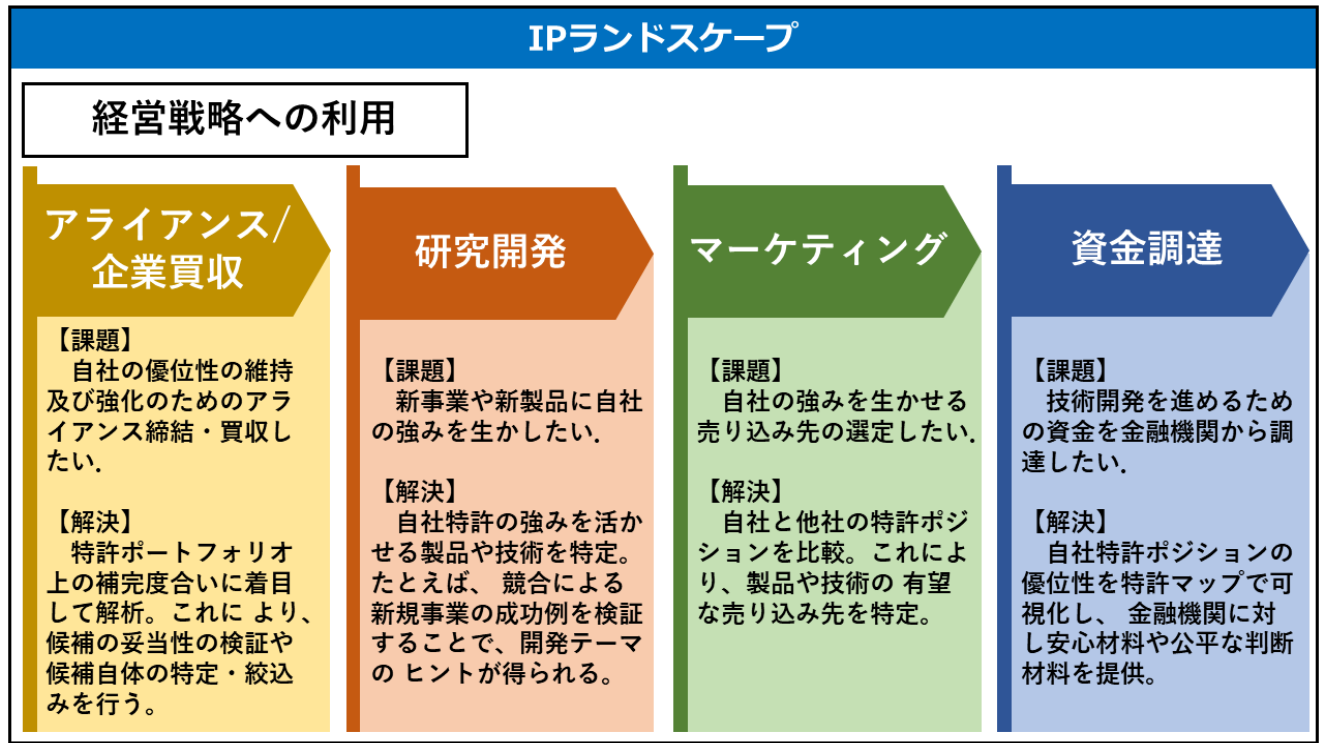


図1 IPランドスケープの活用

2.2 特許情報処理

特許とは知的財産の一部であり、一般的には20年間の期限が設けられている。その期間自身の発明を他者に盗用することを防いだり、他者が発明を利用する際に、使用料金などを受け取ることが許可される。これら特許には特許番号が存在し、特許文章の表紙に記載されており、特定の特許を識別、検索するのに役立っている(図2参照)。また、国際特許分類（International Patent Classification：IPC）は、特許文献の国際的な利用の円滑化を目的に作成された世界共通の特許分類である。現在も技術の進展に柔軟に対応するため、適宜改正が行われている[3]。

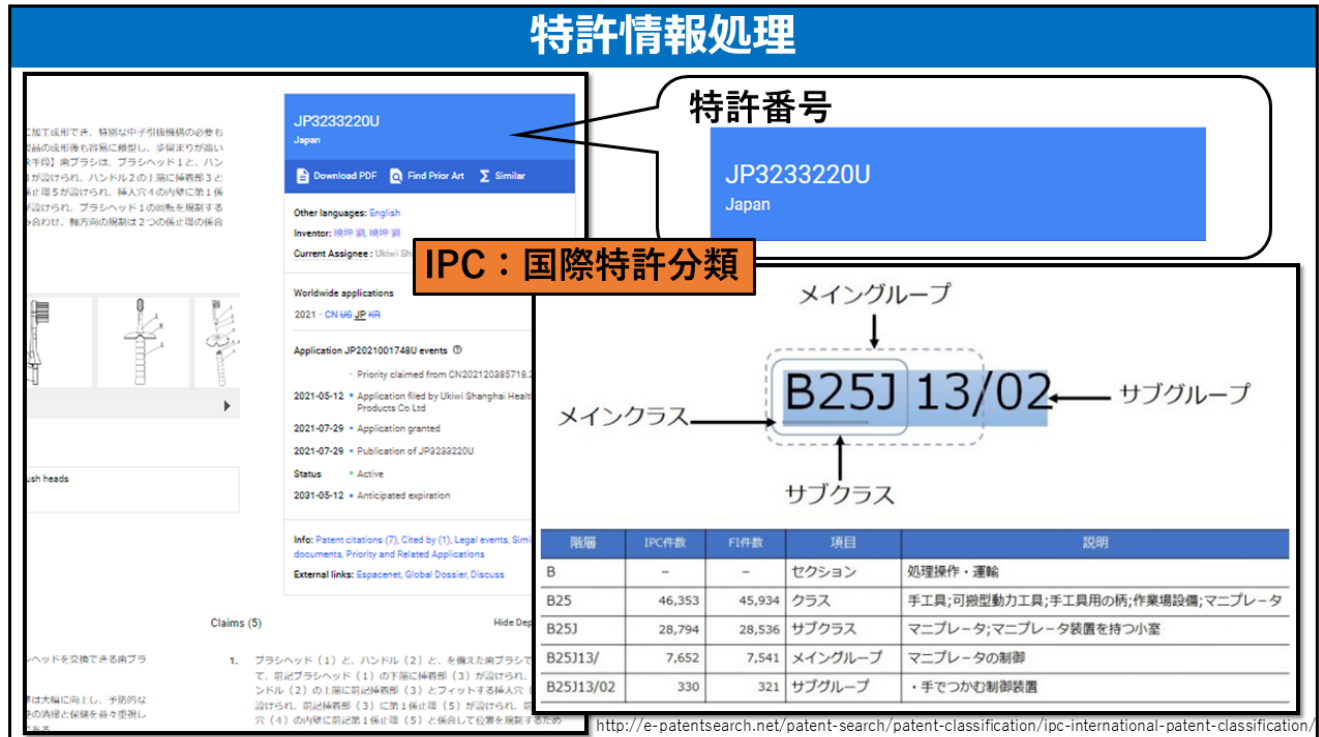


図2 特許に含まれる情報

2.3 自然言語処理とテキストマイニング

自然言語処理とは、人が書いたり話したりする言葉をコンピュータが理解し、処理するための技術である。この分野は、人工知能の重要な部分でありコンピュータが人間のような思考や学習を行うための基礎となっている。

テキストデータは、人間の言葉や意見などの定性的なデータを含んでおり、これらのデータから有益な情報を抽出することがテキストマイニングの目的である。人間は自然言語からアイデアを生み出すことが一般的であるため、インターネット上のテキストデータを自然言語処理することは非常に重要である。現代社会では、インターネット上の情報量は莫大になっており、今後も増え続けることが予想される。これらインターネット上の情報を収集し、分析することでIPランドスケープに生かすことができると考える。

— 3 共起語ネットワークの作成 —

3.1 特許情報のベクトル化

莫大な情報を特許情報の分析を行うためにそれぞれの特許をベクトル化し整理し、全体を俯瞰して見渡せるように、これらの情報を可視化が必要があると考えられる。ベクトル化にはSentence-Bidirectional Encoder Representation from Transform：Sentence-BERTを用いる[4]。Sentence-BERTは、Googleが発表した自然言語処理モデルであるBERTを改善したモデルである。

BERTは2つの文章を比較することには長けているが、複数の文章を比較するには精度がいまいちである。そこでSaimese Networkという手法を用いて複数文章をインプットすることができるようになったものがSentence-BERTである(図3参照)。事前学習にはHugging Faceに登録されている事前学習モデルを使用した。

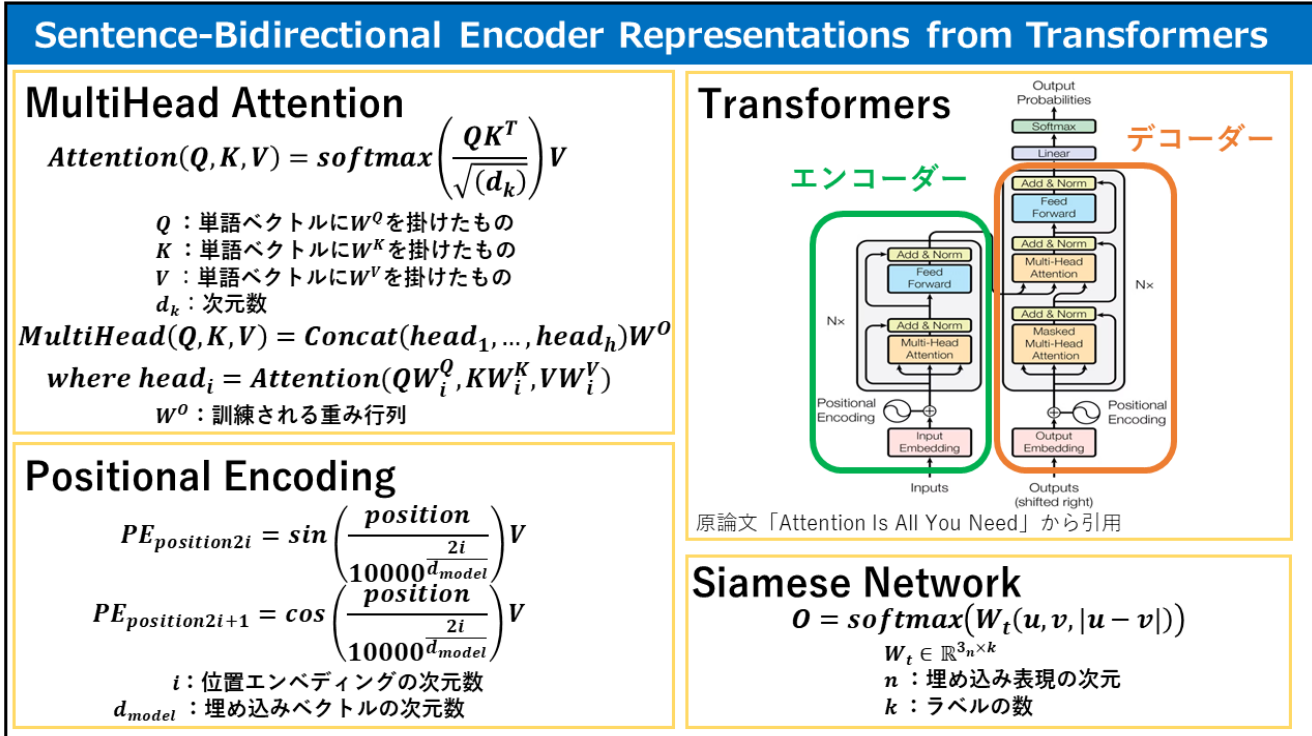


図3 Sentence-BERTによるベクトル化

3.2 次元圧縮とクラスタリング

今回扱うデータは768次元と高次元であるためクラスタリングを行う際に次元の呪いが発生することが考えられるため、次元圧縮を行う。次元圧縮手法にはUniform Manifold Approximation and Projection of Dimension Reduction：UMAPを用いる[5](図4参照)。

さらに、k-means法を用いてクラスタリングを行う[6]。k-meansでは事前にクラスターの数を与える必要があためクラスター数を決定するためにクラスター分析を行う。クラスター分析にはシルエット分析を用いる。シルエット分析におけるシルエット係数は、クラスタリングの品質を評価する指標であり、クラスター内のサンプルがどれだけ密集、分離しているのかを示す指標である。本研究ではシルエット係数が一番大きくなるクラスター数でクラスタリングを行う。

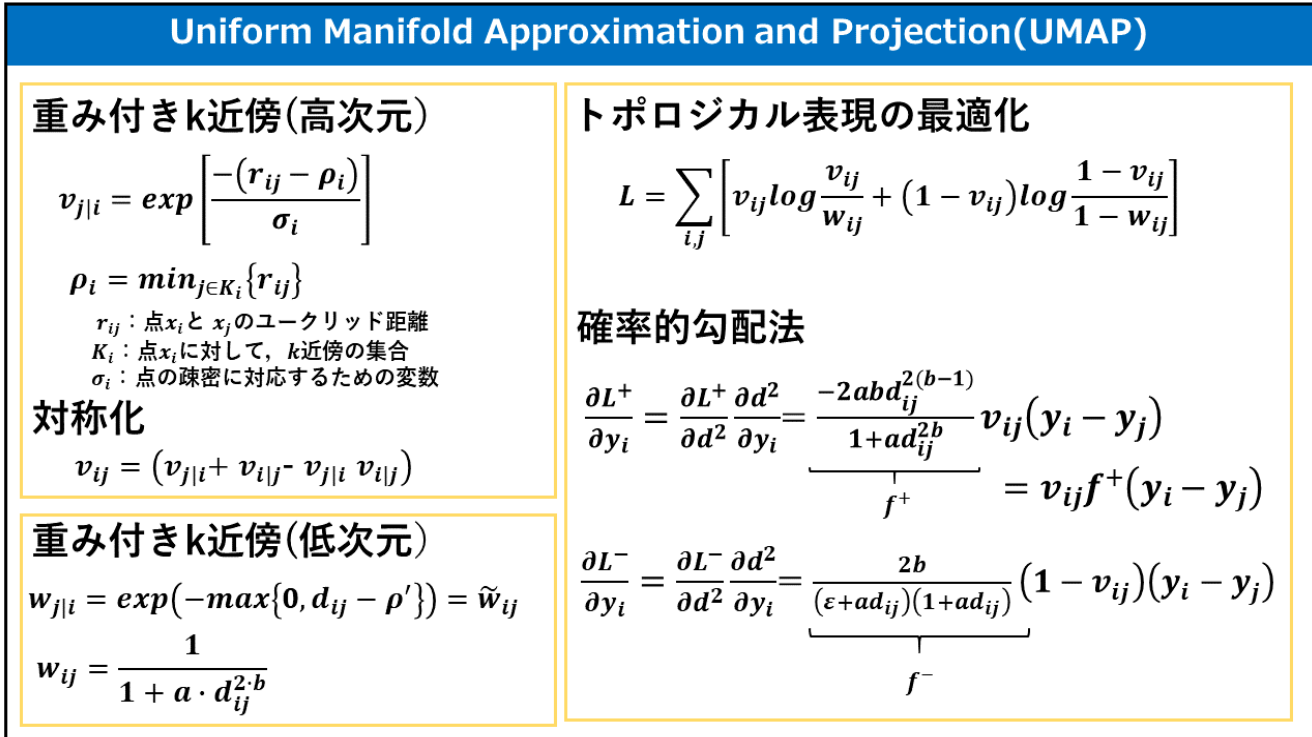


図4 UMAPによる次元圧縮

3.3 共起関係と共起語ネットワーク

関連性の高い単語は、一緒に出現することが多いため、それらの単語の共起関係を調べることで、単語間の関係性を理解することができる。共起分析では単語同士のJacard係数という指標を用いて単語同士の共起度合いを比較し、共起関係にある単語と単語を線で結んで描かれる共起語ネットワークが利用される。このような共起語の分析を通じて、単語同士の意味的な特徴を理解することができる。本研究では、各クラスター内の単語にどのような関係があるのかを理解することを目的とする。

4 提案手法

特許文献の検索サービスである「Google Patents」からキーワードによる検索結果より特許データを取得する。また、取得した特許データに対して、形態素解析などの処理を行ったのち、Sentence-BERTを用いてベクトル化を行う。さらに、次元の呪いを解消するために、次元を圧縮したのち、クラスター分析を行い、その結果をもとにクラスタリングを行う。それらの結果を2次元にプロットし、最後に共起度合いを算出したのち、クラスターごとに共起語ネットワークを作成し、pyvisを用いて3Dグラフにより可視化を行う(図5参照)。

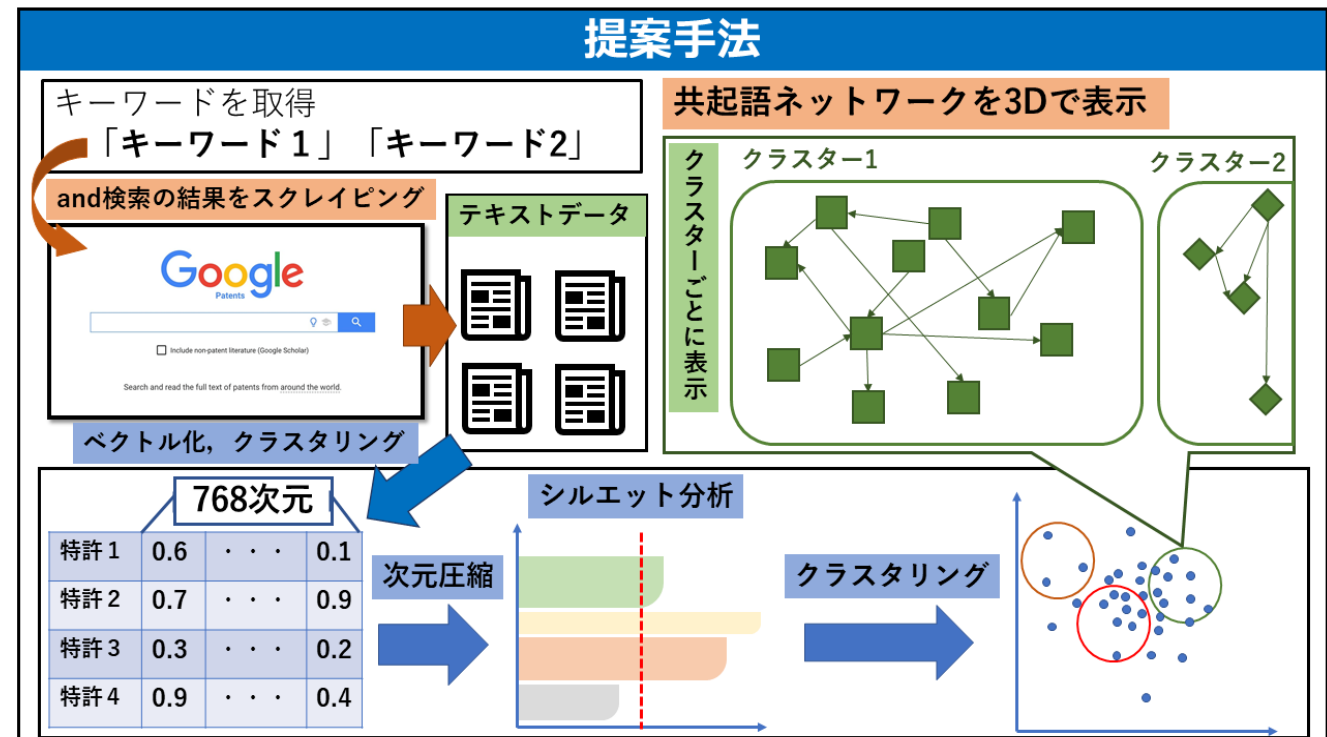


図5 システムの概要図

5 数値実験並びに考察

今回の数値実験では、従来の実例と同じくキーワードを「浸透」「隙間」「狭い」の3つを用いて共起語ネットワークを作成する。実験で扱う特許データは、2000年1月から2022年12月までに出版された特許を用いる。

従来の実例では共起語ネットワークを作成するだけであったが、提案手法では特許情報をベクトル化し、可視化を行うことで、特許全体を俯瞰してみることができ特許の密集具合などが確認可能となった(図6参照)。よって従来よりも広い分野の探索や研究課題の発見が可能になったと考える。一方で、共起語ネットワークの作成にはまだ改善の余地が見られる。特許情報には複合語や専門用語などが多く含まれており、今回行った形態素解析ではそれらの抽出が行えておらず、別々の他の単語として抽出していたと考えられる。

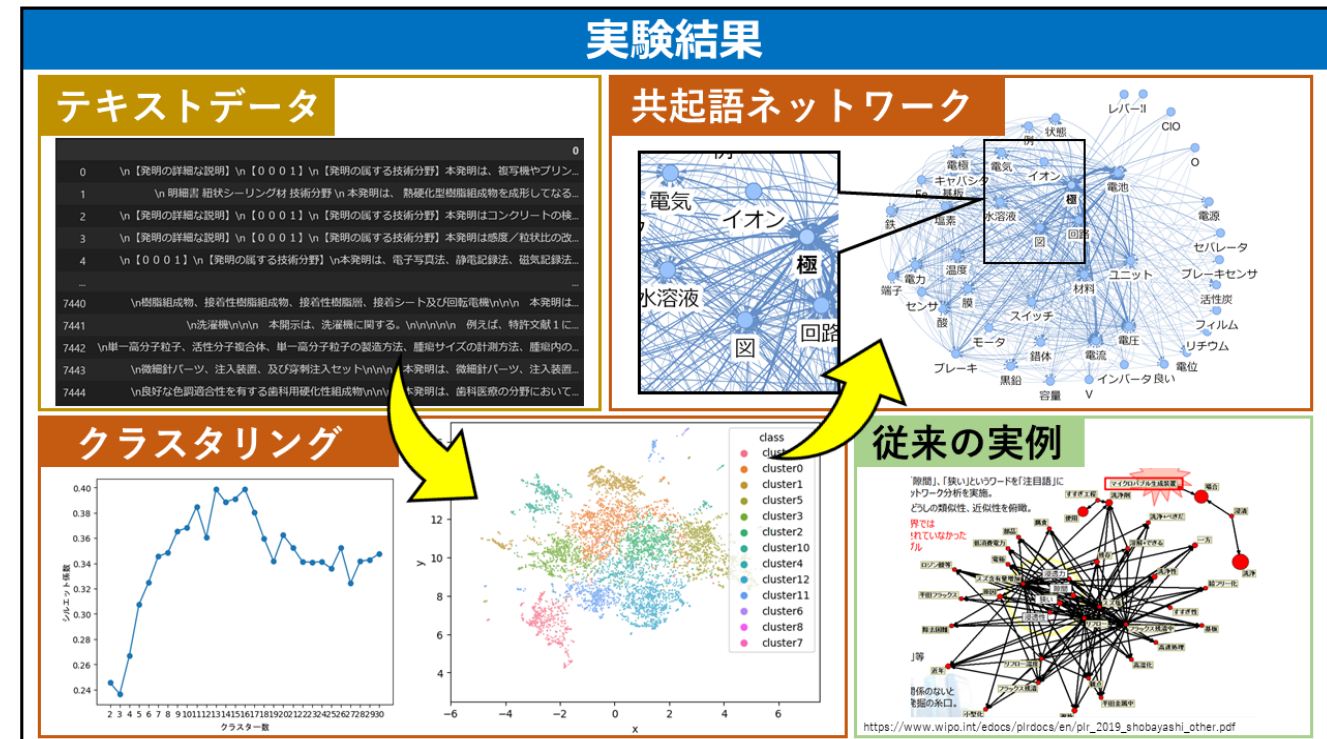


図6 実際に生成された共起語ネットワーク

6 おわりに

莫大な特許情報を整理し、可視化を行うことで、新たな市場・用途・商品・サービスの探索・提案などの支援を行った。今後の課題として、形態素解析を行う際の専門用語や複合語の抽出やクラスターのタイトルをクラスター内の重要語などを用いて作成、3Dグラフのデザインの改善などを行うことで、より視覚的にわかりやすくなると考えられる。さらに、今回の実験ではスクレイピングから共起語ネットワーク作成までの時間が多くかかってしまう問題があり、実用に向いていないと考えらるため実行時間を短縮する必要がある。

参考文献

- [1] 特許庁，“広報誌「とっきょ」”，https://www.jpo.go.jp/news/koho/kohoshi/vol49/01_page1.html，閲覧日 2023. 11. 07
- [2] 特許庁，“経営戦略に資する知財情報分析・活用に関する調査報告書”，<https://www.jpo.go.jp/support/general/document/chizai-jobobunseki-report/chizai-jobobunseki-report.pdf>，閲覧日 2023. 11. 07
- [3] リサーチ・ナビ，日本の特許を特許分類から調べる”，https://rn-avi.ndl.go.jp/jp/patents/post_398.html，閲覧日 2023. 11. 07
- [4] Nils Reimers, Iryna Gurevych. “Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks” ArXiv e-prints, 1908. 10084, 2019
- [5] McInnes, L., Healy, J., Melville J “UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction”, ArXiv e-prints, 1802. 03426, 2018
- [6] Douglas Steinley, Michael J. Brusco, “Initioalizing k-menas Batch Clustering: A Critical Evaluation of Sersveral Techniques”, Journal of Classification, Vol24, No. 1, 99-121, 2007.