

卒業論文

IP ランドスケープによる 経営戦略支援ための 共起語ネットワーク作成

Data Fusion through Web-GIS Visualization
Using Open Data for Evidence-Based Policy Making

富山県立大学 工学部 情報システム工学科
2020032 平井遙斗
指導教員 奥原 浩之 教授
提出年月: 2024年2月

目 次

図一覧	ii
表一覧	iii
記号一覧	iv
第1章 はじめに	1
§ 1.1 本研究の背景	1
§ 1.2 本研究の目的	1
§ 1.3 本論文の概要	1
第2章 知的財産戦略と特許情報	2
§ 2.1 知的財産戦略	2
§ 2.2 特許情報処理	4
§ 2.3 テキストマイニングと自然言語処理	5
第3章 特許情報の可視化	8
§ 3.1 特許情報のベクトル化	8
§ 3.2 次元削減手法とクラスタリング手法	10
§ 3.3 単語間のつながりと共にネットワーク	11
第4章 提案手法	12
§ 4.1 Google Patents からの取得, 分類, 抽出	14
§ 4.2 トピックからの 3D グラフによる可視化	14
§ 4.3 IPL(Intellectual Property Landscape)への活用	14
第5章 数値実験並びに考察	15
§ 5.1 数値実験の概要	15
§ 5.2 実験結果と考察	15
第6章 おわりに	17
謝辞	18
参考文献	19

圖一覽

2.1 IP ランドスケープの概要 [4] 4

表一覽

5.1 「年少人口 [割合]」に対する Direct-LiNGAM の結果 16

記号一覧

以下に本論文において用いられる用語と記号の対応表を示す.

用語	記号
LiNGAM における i 番目の観測変数	x_i
LiNGAM における j 番目の観測変数から i 番目の観測変数へのパス係数	b_{ij}
LiNGAM における i 番目の観測変数に対する誤差（非観測変数）	e_i
主問題における各入力に対する重み	v^T
主問題における各出力に対する重み	u^T
主問題における対象 DMU の評価値	z
CCR モデルにおける DMU _o の入力	x_o
CCR モデルにおける DMU _o の出力	y_o
CCR モデルにおける DMU の入力	X
CCR モデルにおける DMU の出力	Y
双対問題における対象 DMU の評価値	w
入力指向モデルにおける対象 DMU の評価値	θ
入力指向モデルにおける各 DMU に対する重み	λ
出力指向モデルにおける対象 DMU の評価値	η
出力指向モデルにおける各 DMU に対する重み	μ
入力指向モデルにおける対象 DMU の i 番目の入力に対する改善案	\hat{x}_i
入力指向モデルにおける参照集合内の k 番目の DMU の i 番目の入力	x_{ik}
入力指向モデルにおける参照集合内の k 番目の DMU に対する重み	λ
出力指向モデルにおける対象 DMU の j 番目の出力に対する改善案	\hat{y}_j
出力指向モデルにおける参照集合内の k 番目の DMU の j 番目の出力	y_j
出力指向モデルにおける参照集合内の k 番目の DMU に対する重み	μ
提案手法における d 番目の市区町村の i 番目の入力	x_{id}
提案手法における d 番目の市区町村の i 番目の出力	y_{id}
提案手法における d 番目の市区町村に対する重み	λ_d
$robust Z - score$ における正規化後の値	ι
$robust Z - score$ を用いて正規化するデータ集合内の値	x
$robust Z - score$ を用いて正規化するデータ集合	X
$robust Z - score$ を用いて正規化するデータ集合の中央値	$median(x)$
$robust Z - score$ を用いて正規化するデータ集合の正規四分位範囲	$NIQR$
0～1 変換の結果の値	ι'
0～1 変換を行うデータ集合内の値の最大値	$max \iota $

はじめに

§ 1.1 本研究の背景

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 [2]

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 [?]. 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。

§ 1.2 本研究の目的

§ 1.3 本論文の概要

本論文は次のように構成される。

第1章 本研究の背景と目的について説明する。

第2章

第3章

第4章

第5章

第6章 本論文における前章までの内容をまとめつつ，本研究で実現できたことと今後の展望について述べる。

知的財産戦略と特許情報

§ 2.1 知的財産戦略

知的財産戦略とは企業が保有する知的財産を経営戦略の一環として取り入れ、企業の競争力を高め、事業目標を達成することを目的とする戦略である。知的財産には、特許、商標、意匠、著作権、ノウハウなど、さまざまな種類があり、これらの知的財産をどのように活用すれば、企業の価値を最大化できるのかを考えることが重要である [3]。

知的財産戦略は、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門や機能の方向性を決定する重要な役割を果たしている。日本において、知的財産戦略は特許などの知的財産（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」と呼ばれることが多い。

知的財産戦略の目的は、以下の3つにまとめることができる。

企業の競争力を高める

知的財産は、企業の競争力を高める上で重要な役割を果たす。具体的には、競合他社との差別化、新製品・サービスの開発促進、収益向上とブランド力強化の3つの点で、企業の競争力を高める。

例えば、スマートフォンメーカーは、独自の技術やデザインを特許や商標で保護することで、競合他社との差別化を図り、消費者の購買意欲を高めている。また、自動車メーカーは、独自のエンジン技術や安全技術を特許で保護することで、新車の開発につなげ、他社に先駆けて市場シェアを拡大している。さらに、ソフトウェア会社は、自社製品の技術特許をライセンス提供することで、収益を向上させている。

このように、知的財産を戦略的に活用することで、企業は競争力を高め、企業の成長と発展を実現することができる。

事業目標を達成する

知的財産戦略は、企業が掲げる事業目標の達成にも貢献する。具体的には、新市場の開拓、新製品・サービスの開発、ブランド力強化の3つの点で、企業の事業目標の達成を後押しすることができる。

例えば、自動車メーカーが成長戦略を掲げている場合、新興国市場向けに独自の技術を開発することで、新市場の開拓を図り、新車の販売を拡大することができる。また、製薬会社が新薬の開発に特許を取得することで、他社に先駆けて新薬を市場に投入し、収益を拡大することができる。さらに、ファッションブランドが独自のデザインやロ

ゴを特許や商標で保護することで、ブランド価値を高め、消費者からの信頼を得ることができる。

このように、知的財産戦略を活用することで、企業は事業目標の達成を後押しし、企業の成長と発展を実現することができる。

企業価値を向上させる

知的財産は、企業の独自性や将来性を示すものであり、企業の価値を高める上で重要な要素である。企業は、自社の知的財産を適切に管理・活用することで、企業価値を高め、企業の成長と発展を実現することができる。

例えば、Apple の iPhone は、独自のデザインや操作性によって、他社製品と差別化を図り、高いブランド価値を築いている。また、製薬会社が新薬の特許を取得した場合、その新薬の市場規模や将来の収益性を評価することで、企業の将来性を評価することができる。

具体的には、知的財産を活用した新製品・サービスの開発、知的財産の譲渡・ライセンス、知的財産の活用による業務効率化などの方法で、企業価値を高めることができる。企業は、自社の事業目標や状況に応じて、これらの方法を組み合わせて、知的財産を活用して企業価値を高めることが重要である。

経営戦略

「経営戦略」とは、企業が競争環境の中で自らの経営目的・経営目標を達成するための方針や計画全般を意味する。どれほど巨大な企業であっても、保有する経営資源（ヒト、モノ、カネ）は有限だ。企業が掲げる目標や目的に応じて、選択し分配していく必要がある。こうした企業活動の基軸となる指針や指標、また方策を実現するための体制づくりなども「経営戦略」には含まれる。企業はすべてのリソースを有しているわけではない。当然ながら、強みや弱み、特性がある。それらを経営者は理解・把握した上で、組織改革や事業の方向性を決定していかなければならない。やるべきこと、やらなければいけないことは数多くある。それらにどのような優先順位を付けて実行していくかを明確に打ち出していくためにも、戦い方の根幹がどうしても必要になってくる。それが、「経営戦略」を策定する目的と言って良いだろう。

グローバル化の進展や IT・AI の普及、ニーズの多様化、競争環境の激化など、現代は変化のスピードがますます増している。こうした時代において、企業は 10 年、20 年先の生き残りに向けてどのような成長シナリオを描いていくかが、一段と問われるようになってきている。そのためにも、経営者は自社の強みや特性を把握・理解し、組織改革や事業の方向性をスピーディ、かつダイナミックに決定していかなければならない。「経営戦略」の必要性が高まっているのもそのためである。

経営戦略のフレームワーク

経営戦略の策定では自社を取り巻く外部の環境要因に打ついて分析する外部環境分析や、自社内の環境を分析する内部環境分析を踏まえ自社の強みや弱み、機械や脅威を把握することで、戦略オプションを立案して最適な戦略を選択することが大切である。それらを行

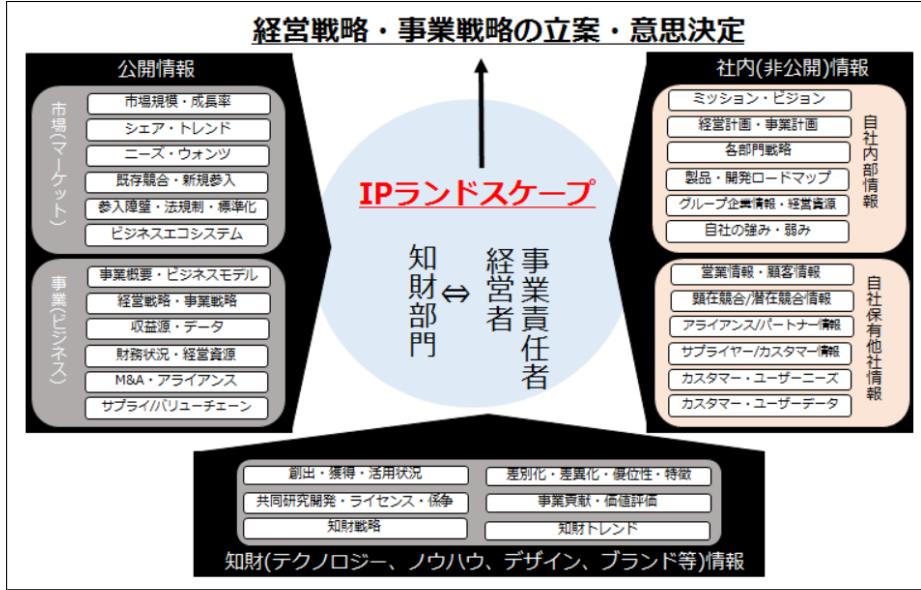


図 2.1: IP ランドスケープの概要 [4]

うために役立つ代表的なフレームワークとして、PEST 分析ファイブフォース分析、3C 分析、VRIO 分析、SWOT 分析、STP 分析、4P 分析などが挙げられる [5].

内閣府や特許庁による IP ランドスケープの積極的な推進に代表されるように、IP ランドスケープは研究機関においても積極的に検討されるべき対象であると考えられる。また、その具体的な取り組みの多くに ICT を活用した取り組みが多数行われていることから、IP ランドスケープの効率的な実施には ICT の活用が不可欠であり、情報工学との親和性が高いものと思われる。これらのことから、本研究は情報技術を用いた IP ランドスケープの支援を目的とする。

§ 2.2 特許情報処理

特許情報とは、特許・実用新案・意匠・商標の出願や権利化に伴って生み出される情報である。この情報は、研究開発の重複防止、既存技術の活用、無用な紛争の回避などに役立つ。

特許情報は、研究開発の策定から商品化、更には他人の権利調査に至るまでの様々な事業活動において活用されている。

具体的な活用例は、以下のとおりである。[7].

特許情報の活用例

- 技術動向調査

将来性を見据えた研究テーマの選定や過去になされた研究との重複回避のために、特許情報を利用して技術動向調査が行われます。特定の技術分野における特許出願の動向や出願件数の推移を調査することにより、過去にどのような技術が存在したか、また、今後開発すべき技術分野の把握の参考になります。

- 出願前の先行技術調査

研究成果として発明がなされたとき、権利化するか否かの判断が必要となります。特許出願をする際に関連する分野の先行技術について調査することにより、権利として認められる見込みのない無駄な出願を未然に防止することができます。

- 権利調査

開発製品が他人の産業財産権を侵害すると、製造・販売の中止や製造品の廃棄、あるいは権利者への損害賠償にまで発展する恐れがあります。これらを未然に防止するために、設計から製造前段階にかけて、他人の権利範囲の調査を行います。

- 公知例調査

他の権利者から警告を受けた場合などの対抗手段として、自社の発明・考案を事業化する際に障害となる他人の特許権・実用新案権を無効にするため、その特許・実用新案登録の出願前の公知例を調査します。

- 公知例調査

事業を営む上で多くの場合には競合他社が存在しています。その競合他社がどのような戦略で事業を行っているか調査する上で、特許情報は貴重な情報源となります。競合他社の過去から現在に至るまでの出願動向を把握することにより、研究開発動向等を読み取ることが可能です。また、競合他社の出願動向を継続的に監視し、自社にとって障害となる出願等の早期発見に努めることも重要です。

§ 2.3 テキストマイニングと自然言語処理

テキストマイニングとは、定型化されていない文章から情報を抽出する技術です。SNSやアンケート、コールセンターの応対など、さまざまな場面で活用されています。テキストマイニングは、AI技術の進展により、より高度な分析が可能になりました。また、テキストデータの量も増加しており、テキストマイニングツールの種類も増えています。^[8]

テキストマイニングを行うことで、企業は、顧客のニーズや市場動向を把握したり、新製品の開発やマーケティングの戦略を策定したりすることができる。

このことによって、単一のデータの可視化のみでは表面化してこなかった課題をくみ取ることや、逆に、課題に対する解決策を一見関係のなさそうな分野から発見するといったことが可能となる。

形態素解析

形態素解析は、

分かち書き

自然言語処理（NLP）において、分かち書きは、テキストを単語や句などの意味的な単位に分割する処理である。分かち書きは、テキストの意味理解や解析の基礎となる重要な処理であり、多くのNLPタスクで必要となる。

分かち書きの目的は、テキストの意味を正確に理解するために、テキストを単語や句などの意味的な単位に分割することである。例えば、文の意味を理解するためには、文を主語、述語、目的語などの句に分割する必要がある。また、単語の意味を理解するためには、単語を品詞や語義などの単位に分割する必要がある。

分かち書きの処理方法は、大きく分けて以下の2つに分けられる [6]。

1. ルールベース型

ルールベース型分かち書きは、あらかじめ定義された対象となる言語の文法ルールに基づいて分かち書きを行う方法である。ルールベース型分かち書きは、人手でルールを定義するため、単純な分かち書きを行う場合は比較的容易に実装でき、調整も可能であるが、複雑な分かち書きを行う場合は、ルールを複雑にする必要があり、高度な専門知識が必要となり、誤りが生じやすくなる。

2. 統計学習ベース型

統計学習ベース型分かち書きは、機械学習によって導き出されたルールに基づいて分かち書きを行う方法である。統計学習ベース型分かち書きは、複雑な分かち書きを行う場合でも、比較的正確に分かち書きを行うことができる。また、機械学習に大量のテキストデータが必要であり、計算量が大きいという問題もコンピュータの高速化と低価格化により解決に向かっている。

分かち書きの精度は、分かち書きの目的や、分かち書きを行うテキストの種類によって異なる。例えば、新聞記事などのフォーマルなテキストであれば、ルールベース型分かち書きでも比較的高い精度で分かち書きを行うことができる。一方、SNSの投稿などの非フォーマルなテキストであれば、統計学習ベース分かち書きの方が高い精度で分かち書きを行うことができる。

近年、NLP技術の進展により、分かち書きの精度も向上している。また、クラウドサービスやオープンソースソフトウェアの普及により、分かち書きの利用が容易になってきている。

また、現状の分かち書きには、以下の課題がある。

- 日本語の曖昧さ

ルールベース型分かち書きは、あらかじめ定義されたルールに基づいて分かち書きを行う方法である。ルールベース型分かち書きは、単純日本語は、英語と比べて曖昧な表現が多い言語である。例えば、「私は、彼に会いました。」という文は、文法的には「私は、彼に会いに行きました。」という意味にも解釈できる。このような曖昧な表現を正確に分かち書きすることは、困難である。

- 新語や流行語

常に新しい言葉や表現が生まれてくるため、分かち書きのルールや統計モデルを常に更新する必要がある。

- 誤ったデータの影響分かち書きの精度は、分かち書きの対象となるデータの品質に大きく影響を受ける。誤ったデータが含まれていると、分かち書きの精度が低下する。

今回用いる特許の本文には、専門的な用語や複合語が多数含まれているため、それらを正しく抽出する必要がある。そのため、python のモジュール termextract を用いて専門用語や複合語の抽出を行い、それらを分かち書きの辞書に登録する。

<termextract>

今後、テキストマイニングと自然言語処理は、AI や ML 技術を活用することで、より高度な分析が可能となり、より幅広い分野で活用されるようになると想われる。また、テキストデータの量の増加に対応するため、テキストマイニングと自然言語処理の自動化や、テキストデータの検索・分析・活用を効率化する技術の開発が進んでいくと考えられる..

特許情報の可視化

§ 3.1 特許情報のベクトル化

特許情報は、日々蓄積され、今では莫大な量となっており、それらの分析は困難を極める。そこで、特許情報を効率的に分析するためには、各特許をベクトル化して整理をおこない、全体を俯瞰できるように可視化する必要があると考える。本研究では、特許本文の文章を対象にベクトル化を行う。特許本文には、特許技術の内容が詳細に記載されているため、これらの情報をベクトル化することで、特許の技術分野や技術トレンドなどを把握することができると考える。

具体的には、特許本文を Sentence-Bidirectional Encoder Representation from Transform : Sentence-BERT を用いることで文章全体を単位にベクトル化を行う。Sentence-BERT は、Bidirectional Encoder Representations from Transformers : BERT をベースに開発されており、文章の単語の順序を考慮して、文章の意味を表現するベクトルを生成する。

Sentence-BERT は、文章の意味を理解する能力に優れているため、自然言語処理の様々なタスクに活用されている。

Transformer

近年、翻訳などの入力文章を別の文章で出力するというモデルは、Attention を用いたエンコーダー、デコーダ形式の RNN や CNN が主流であった。しかし、Transformer は、RNN や CNN を用いず Attention のみを用いたモデルである。Transformer は、再帰も畳み込みも一切行わないので並列化が容易であり、他のタスクにも汎用性が高いという特徴がある。Transformerにおいては Attention を多数並列に配置した Multi-Head Attention が用いられ、一般的に以下の式 (3.2) のように定式化される [9]。

<Multi-Head Attention>

$$\text{MultiHeadAttention}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h)W_o \quad (3.1)$$

$$\text{where } \text{head}_i = \text{ScaledDotProductAttention}(QW_i^Q, KW_i^K, VW_i^V) \quad (3.2)$$

ここで、Scaled Dot-Product Attention では、内積を利用したベクトル間の類似性に基づく変換を行う。

<Scaled Dot-Product Attention>

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (3.3)$$

3.2では、学習パラメータを持っていないScaled Dot-Product Attentionの表現力を広げるために、入力の直前に学習パラメータを持つLinear層の追加を行っている。これにより、入力されるベクトルの特徴空間に依存しない注意表現を学習することができる。Linear層の追加を行ったScaled Dot-Product Attentionを一般にSingle-Head Attentionを呼ぶ。

Scale Dot-Product Attentionは、ある単語に対して、その単語が文章に含まれる単語とどれだけ類似しているのかを計算し、それらを確率的に表現したものである。TransformerにおけるAttentionの入力には主に以下の2種類の入力方法が用いられている。

1. Self-Attention (softmaxに与えるQuery, Key, Valueと同じ値にする)
2. SourceTarget-Attention (Key, Value同じ値にし, Queryを異なる値にする)

Single-Head Attentionでは多種多様な意味や文法をもつ単語に対しても单一の注意表現が生成される。そこで、Single-Head Attentionを多数並列に配置してMulti-Headにすることで、複数の特徴部分空間における注意表現の獲得をすることができる。

以上のことから、文章を行列で表せることが分かった。しかし、文章というのは、文字を読む方向が重要であり、行列として表され、かつ、一括で処理する場合、文字の順番の概念がなくなってしまう。これは、文章を正しく扱えなくなる可能性がある。そのため、Embedding層からの行列に位置情報を含んだ行列を足し合わせることで、文字の順番の概念を扱えるようにする必要がある。これを可能にするのがPositional Encodingである。

<Positional Encoding>

$$PE_{(pos, 2i)} = \sin\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right) \quad (3.4)$$

$$PE_{(pos, 2i+1)} = \cos\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right) \quad (3.5)$$

入力文章の単語数が50個まで扱えて、Embedding層の埋め込み次元数が128次元の場合、Positional Encodingが生成する行列は128次元の行ベクトルが縦に50個並んだ行列になる。この行列は、各行のベクトルが絶対に同じものにならいため、この行列から単語の位置情報を表すことができる。具体的には、行ベクトルの各次元は、単語の位置情報に応じて、異なる値が割り当てられている。例えば、最初の行ベクトルの最初の次元は、単語の位置が0であることを示し、最後の行のベクトルは、単語の位置が49であることを示す。このように、Positional Encodingは、単語の位置情報を行ベクトルに埋め込むことで、Transformerモデルが単語の順序情報を利用でいるようにしている。

BERT

自然言語処理タスクにおいて、精度向上には言語モデルによる事前学習が有効である。この言語モデルによる事前学習には「特徴量ベース」と「ファインチューニング」の2つの方法がある。まず、「特徴量ベース」とは事前学習で得られた表現ベクトルを特徴量の1つとして用いるもので、タスクごとにアーキテクチャを定義する。ELMo[Peters, (2018)]がこ

の例である。また、「ファインチューニング」は事前学習によって得られたパラメータを重みの初期値として学習させるもので、タスクごとでパラメータを変える必要があまりない。例として OpenAI GPT[Radford, (2018)] がある。ただし、いずれもある問題がある。それは事前学習に用いる言語モデルの方向が 1 方向だけということだ

[Sentence-BERT]

BERT では 2 つの文章を入力し、それらの類似度を測ることができる。しかし、複数の文章を入力する場合は BERT では容易ではない。そこで本研究では Sentence-BERT を用いる。BERT で求められた埋め込み表現を pooling し、それらを Softmax 関数を用いて、分類を行う。

$$O = \text{softmax}(W_t(u, v, \|u - v\|))W_t \in R^{3n \times k} \quad (3.6)$$

事前学習モデルは Hugging Face や GitHub などのサイト公開されている。また東京大学や京都大学なども独自のモデルを公開している。本研究では Hugging Face に登録されている ”sonoisa/sentence-bert-base-ja-mean-tokens” を用いる。

§ 3.2 次元削減手法とクラスタリング手法

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。

UMAP

<重み付き k 近傍（高次元）>

$$v_{j|i} = \exp\left[\frac{-(r_{ij} - \rho_i)}{\sigma}\right] \quad (3.7)$$

$$\rho_i = \min_{j \in K} r_{ij} \quad (3.8)$$

<対称化>

$$v_{ij} = (v_{j|i} + v_{i|j}) - v_{j|i}v_{i|j} \quad (3.9)$$

<重み付き k 近傍（低次元）>

$$w_{ij} = \exp(-\max\{0, d_{ij} - \rho'\}) = \tilde{w}_{ij} \quad (3.10)$$

<対称化>

$$w_{ij} = \frac{1}{1 + a \cdot d_{ij}^{2-b}} \quad (3.11)$$

<トポロジカル表現の最適化>

$$L = \sum [v_{ij} \log \frac{v_{ij}}{w_{ij}} + (1 - v_{ij}) \log \frac{1 - v_{ij}}{1 - w_{ij}}] \quad (3.12)$$

§ 3.3 単語間のつながりと共起ネットワーク

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 Jaccard 係数とい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。

提案手法

- § 4.1 Google Patentsからの取得，分類，抽出
- § 4.2 トピックからの3Dグラフによる可視化
- § 4.3 IPL(Intellectual Property Landscape)への活用

数値実験並びに考察

§ 5.1 数値実験の概要

§ 5.2 実験結果と考察

第6章

おわりに

謝辞

本研究を遂行するにあたり、多大なご指導と終始懇切丁寧なご鞭撻を賜った富山県立大学工学部電子・情報工学科情報基盤工学講座の奥原浩之教授, António Oliveira Nzinga René講師に深甚な謝意を表します。最後になりましたが、多大な協力をしていただいた研究室の同輩諸氏に感謝致します。

2024年2月

平井 遥斗

参考文献

- [1] 特許庁, ”広報誌「とっきょ」”, 閲覧日 2024-02-04,
[https://www.jpo.go.jp/news/koho/kohoshi/.](https://www.jpo.go.jp/news/koho/kohoshi/)
- [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”, 閲覧日 2024-02-04,
[https://www.jpo.go.jp/support/general/document/chizaijobobunseki-report/chizai-jobobunseki-report.pdf.](https://www.jpo.go.jp/support/general/document/chizaijobobunseki-report/chizai-jobobunseki-report.pdf)
- [3] 東京知的財産総合センター, ”中小企業経営者のための知的財産戦略マニュアル”, 閲覧日 2024-02-04,
[https://www.tokyo-kosha.or.jp/chizai/manual/senryaku/rmepal000001vypy-att/senryaku_all_vol.9.pdf.](https://www.tokyo-kosha.or.jp/chizai/manual/senryaku/rmepal000001vypy-att/senryaku_all_vol.9.pdf)
- [4] 特許庁, ”「経営戦略に資する知財情報分析・活用に関する調査研究」について”, 閲覧日 2024-02-04,
[https://www.jpo.go.jp/support/general/chizai-jobobunseki-report.html.](https://www.jpo.go.jp/support/general/chizai-jobobunseki-report.html)
- [5] 金融ナビ, ”経営戦略の策定に役立つフレームワーク 7つ | 経営戦略の代表例も解説”, 閲覧日 2024-02-04,
[https://financenavi.jp/basic-knowledge/management_strategy_framework/#tag1.](https://financenavi.jp/basic-knowledge/management_strategy_framework/#tag1)
- [6] gikyo.jp, ”Perl による自然言語処理入門”, 閲覧日 2024-02-04,
[https://gihyo.jp/dev/serial/01/perl-hackers-hub/0031011.](https://gihyo.jp/dev/serial/01/perl-hackers-hub/0031011)
- [7] 特許庁, ”2019年度_知的財産権制度入門”, 閲覧日 2024-02-04,
[https://www.jpo.go.jp/news/shinchaku/event/seminer/text/document/2019_syosinsya/1_3.pdf.](https://www.jpo.go.jp/news/shinchaku/event/seminer/text/document/2019_syosinsya/1_3.pdf)
- [8] 株式会社 日立ソリューションズ・クリエイト, ”テキストマイニングとは？ 手法や活用法を解説”, 閲覧日 2024-02-04,
[https://www.hitachi-solutions-create.co.jp/column/technology/text-mining.html.](https://www.hitachi-solutions-create.co.jp/column/technology/text-mining.html)
- [9] AGIRobots Blog, ”【Transformer の基礎】Multi-Head Attention の仕組み”, 閲覧日 2024-02-04,
[https://developers.agirobots.com/jp/multi-head-attention/.](https://developers.agirobots.com/jp/multi-head-attention/)

