

要約

近年人工知能(AI)などの情報処理技術は目覚ましく発展しており、記憶や認識、データ収集やその処理などは人間を凌駕しつつある。特許情報は過去の情報をアーカイブしたいわば発明の保管庫的なデータであり、それを活用することで経営戦略・技術的発展等広く社会に役立てることができる。しかし、現状の特許プラットフォームは人手で少数の特許事例を調べるのには必要充分であるが、ビッグデータとして特許全体の分析を行いたい場合には整理されているとはいがたい。

キーワード：自然言語処理、業務推進系システム、特許情報処理、テキストマイニング

1 はじめに



図1 多目的最適化の定式化

2.3 自然言語処理

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で処理する技術です。人工知能(AI)の研究分野で中核を成す要素技術の一つといえます。自然言語処理技術は「言語理解」と「言語生成」に大きく二つに分けることができます。「言語理解」は人が書いた文章に対してなんらかの処理をする技術で、メールの自動分類、ウェブ検索などが典型的な応用になります。「言語生成」は、コンピュータに文章を生成させる技術で、文章の要約や機械翻訳などを含みます。これまで個別の用途ごとに技術開発が進んできましたが、ChatGPTをはじめとする最近のシステムがこの常識を変えました。高度な「言語理解」と「言語生成」が必要な質問応答もできるようになり、さまざまな作業(タスク)を一つのシステムでこなせるようになっています。実はChatGPTが世間を騒がせる前から、自然言語処理の研究者の間では技術の急速な進歩に驚きの声が上がっていました。2018年にGoogleが発表した「BERT(バート)」というシステムでは、開発者が少し手を加えるだけでさまざまなタスクに使えるようになりました。それだけでも驚きましたが、ChatGPTの前身である「GPT-2」や「GPT-3」では、システム自体を変更せずとも、人がシステムにあわせて入力を工夫するだけで多様なタスクの実行が可能になりました。さらに、ChatGPTは人との対話能力が強化され、人間が人間に頼むような言葉で指示をするだけで、さまざまなタスクができるようになりました。形態素解析とは文を形態素ごとに分解する技術である[3]。自然言語処理の一つでテキストを品詞ごとに分解することである。形態素解析を行うことで取り出したい品詞を絞つて分析できる。一般的に助詞や助動詞はよく使われるが、キーワードごとのテキストを分析したときに特徴が見られないと考える。

—3 トピックモデル—

3.1 スクレイピングによるテキストマイニング

テキストデータは、「定性データ」の代表的なもので、この「定性データ」から付加価値の高い情報を収集することがテキストマイニングの目的である。アイデア発想において人間は自然言語から思考して発想することが一般的である。そこでサイバー空間にあるテキストデータを自然言語処理することを考える。現代社会において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。このインターネット上の情報を収集して分析することで発想支援に生かせると考える。発想支援において重要なことはキーワードからより関連度の高い単語をより多く表示させることである。そこで、より良いデータを多く収集するためにインターネットからテキストデータを収集することとする。

今回、GooglePatents複数キーワードのand検索の結果を年代ごとに取得し、そのURLからテキストを抽出しそのテキストに対し自然言語処理を行う。




図2 データ収集の流れ

3.2 特許情報のベクトル化とクラスタリング

クラスタリング(clustering)とは、機械学習の1種でデータ間の類似度にもとづいて、データをグループ分けする手法です。この単語は機械学習や統計学の文脈以外でも使われるクラスタリングにはハードとソフトの2種類があります。それぞれのデータが単一のグループに所属するようにグルーピングするものをハードクラスタリ

ング、それが複数のグループに所属できることを許してグルーピングするものをソフトクラスタリングといいます。ことが多いため、これらの分野で用いられる際にはクラスタ分析やデータ・クラスタリングと呼ばれるのが通例となっています。

「群平均法」は、2つのクラスターに属している対象の間のすべての組み合わせの距離を求め、それらの平均値をクラスター間の距離として定める手法です。群平均法は鎖効果を防止できるメリットがあるためウォード法を実行した時に起こってしまう鎖効果(1つのクラスターに対象が1つずつ吸収されていき、新しいクラスターが作られる現象)を未然に防ぐことができます。

「ウォード法」は、凝集型のクラスター分析の手法の1つで「凝集型階層的クラスタリング」とも呼ばれています。ウォード法はすでにあるクラスターの中で、1番距離の近い2つのクラスターが選ばれ、1つのクラスターに結合されていく操作を、目標のクラスター数になるまで続ける方法です。

最短距離法は単連結法とも呼ばれる、2つのクラスター間で一番近いデータ同士の距離を、クラスター間の距離として採用する手法です。群平均法と同様に、クラスターを構成する要素同士の距離をすべて求め、その中で一番距離の短い組み合わせを選ぶことでクラスター間の距離として求めます。この方法のメリットはウォード法などと比較した場合に、計算量が少くなりますが、同時に外れ値に弱いというデメリットも抱えています。

最長距離法とは、最短距離法とは逆の方法で行う計算手法です。完全連結法と呼ばれることもあります。クラスターを構成している要素同士のすべての距離の中で、最も距離が長いものをクラスター間の距離として採用するという手法です。

非階層クラスタリングは、階層を作らずにデータをグループ化していく手法です。母集団の中で近いデータを収集し、指定された数のクラスターに分類します。この方法では階層クラスタリングとは対照的に、クラスターを形成した後で自由にクラスターを分けることができないため、事前にクラスター数を指定する必要があります。

k-means法とは、非階層クラスタリングを行うためのアルゴリズムのことです。「指定されたk個のクラスターに、平均(means)を用いて分類していく」という意味が込められています。そんなk-means法は、初めに指定したクラスターの数だけ「重心」をランダムに指定して、その重心をもとにクラスターをグルーピングしていくという手法です。k-means法を活用すれば、データ間の距離を計算する必要がなくなるというメリットがあります。




図1 データの収集と活用

3.3 共起関係と共起ネットワーク

ある単語とある単語が同時に出現することを共起するといい、文章において関係深い単語は共起することが多い。共起分析では単語同士のJaccard係数を比較したり、共起関係を持つ単語と単語を線で結んで描かれる共起ネットワークが利用される。文章または単語群に対して共起する単語をネットワークで表した共起ネットワークという。今回、キーワードごとに集めたテキストに対してそれぞれの共起ネットワークを作成する。

4 提案手法

- [1]
- [2]
- [3]
- [4]
- [5]

まだ未定

図4 自動献立作成の流れ

5 数値実験並びに考察

まだ未定

図5 実験結果

6 おわりに