

リンク予測モデルによる多言語上位下位関係の自動抽出

玊尧¹ 福田悟志¹ 難波英嗣¹

概要: 自然言語処理において、上位下位語関係は知識体系の中核であり、多くの下流タスクに役立つ。特許を対象とした技術動向調査や審査等はその一例である。しかし、このような用語間の関係を人手で整備するには非常にコストがかかる。本稿では、日本語、英語、中国語で記載された特許テキストデータから上位下位関係を抽出し、多言語シソーラスを自動構築する。提案手法は次に述べる 2 つのステップから構成される。まず、GAN(Generative Adversarial Network)を用いて上位下位関係にある用語を識別する。次に、前の手順で構築された上位下位関係のグラフに対し、ConvE と GraphSAGE を組み合わせたリンク予測を行い、本来であれば上位下位関係にあるべき欠落したエッジを予測する。提案手法の有効性を確認するために行った実験では、GAN を用いた上位下位関係の識別および ConvE と GraphSAGE を組み合わせたリンク予測の両方において、提案手法が従来手法よりも優れていることがわかった。

キーワード: 上位下位関係, 多言語, GAN, リンク予測, 情報抽出, 特許

Automatic Extraction of Multilingual Hypernym-Hyponym Relation Using Link Prediction Model

YAO GONG¹ SATOSHI FUKUDA¹
HIDETSUGU NANBA¹

Abstract: In natural language processing, hypernym-hyponym relations are the core of the body of knowledge (BOK) and is useful for many downstream tasks. An example of this is technical trend analysis and examination of patents. However, it is very costly to manually maintain these relationships between terms. In this paper, we extract hypernym-hyponym relations from patent text data written in Japanese, English, and Chinese, and automatically construct a multilingual thesaurus. The proposed method consisting of the following two steps. Firstly, we use GAN (Generative Adversarial Network) to identify the terms in a hypernym-hyponym relation. Secondly, ConvE and GraphSAGE are combined to predict links on the graph of hypernym-hyponym relations constructed in the previous step, predict missing edges that should be in a hypernym-hyponym relationship. Experiments conducted to demonstrate the effectiveness of the proposed method, it was found that our method outperforms previous methods in both the identification of hypernym-hyponym relations using GAN and link prediction using a combination of ConvE and GraphSAGE.

Keywords: hypernym-hyponym relation, multilingual, GAN, link prediction, information extraction, patent

1. はじめに

本稿では、日本語、英語、中国語で記載された特許テキストデータから上位下位関係を抽出し、多言語シソーラスを自動構築する手法を提案する。用語の上位下位関係をまとめたシソーラスは、技術動向調査や審査等、様々な場面で役に立つ。その一方で、このような用語間の関係を人手で整備するには非常にコストがかかるため、その自動構築が望まれている。

定型表現を用いて上位下位関係を獲得する手法は早くから研究されてきている。Hearst[13]は語彙統語パターンを用いて英語の新聞記事から上位下位関係を抽出している。本研究でも、多言語シソーラス構築の第一歩として、「A や B などの C」、「D such as E, F」と「G 包括 H 和 I」といった多言語の定型表現を利用し、上位下位関係の候補となる用語対を獲得する。

定型表現を利用して抽出された上位下位用語対の候補

に対し、次に述べる 2 つのステップで多言語シソーラスを構築する。まず、GAN(Generative Adversarial Network) [2]を用いて、上位下位関係にある用語を識別する識別器を構築する。次に、前の手順で構築された上位下位関係のグラフに対し、リンク予測技術を適用して、本来であれば上位下位関係にあるべき欠落したエッジを予測する。

リンク予測タスクはノード間の欠落関係を予測し、大規模なグラフ構造のデータを自動的に理解するための重要な鍵である。これまでのリンク予測に関する研究では、大規模な知識グラフ[3, 14]に焦点が当てられていたが、上位下位関係のリンクを予測する研究はこれまでにほとんどない。ConvE[1]などの CNN(Convolutional Neural Network)モデルは、様々な予測タスクにおいて非常に役立つことが証明されている。GNN(Graph Neural Network)に関する embedding を計算する手法のひとつである GraphSAGE[17]はリンク予測タスクを解決するための有効なアプローチを提供されている。本研究では、ConvE と GraphSAGE を組み合わせ、新

¹ 中央大学
Chuo University

たな手法を用いて欠落上位下位関係を予測する手法を提案する。上位下位関係のリンク予測では、図1に示すように各単語をグラフのノードへと変換し、グラフ中のノード間のリンク・エッジの存在を予測する。

図2は日本国特許(特開 2008-157094、特開 2012-182131)の内容であり、「A や B などの C」という定型表現を利用し、図3に示すように上位語と下位語を獲得している。「車両」は上位関係に対して、「乗用車」と「トラック」が下位関係である。「大型電源」は上位関係に対して、「車載用電源」と「定置型電源」が下位関係である。

これにより構築された多言語ソーラスを用いることで、多言語間での一貫性と正確性を高めることを目指している。また、専門文書や科学文献から新たな関係と知識の発見が期待される。

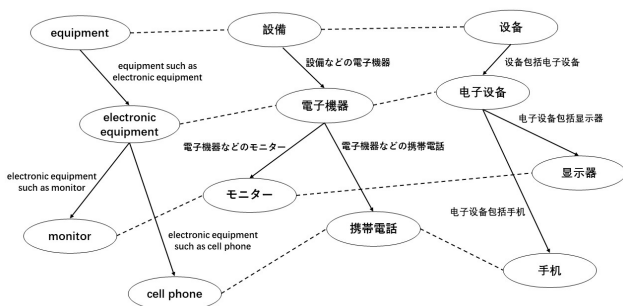


図1：多言語上位下位関係のグラフ

特開 2008-157094: 乗用車やトラックなどの車両に搭載されるガソリンエンジン、ディーゼルエンジンなどの内燃機関において、燃料を吸気ポートではなく、燃焼室(気筒)に直接噴射する筒内噴射式内燃機関が従来から知られている。この筒内噴射式内燃機関では、吸気弁の開放時に、空気が吸気ポートから燃焼室に吸入され、この吸気行程時またはピストンが上昇して吸入空気を圧縮する圧縮行程時に、燃料噴射弁が燃焼室に対して燃料を直接噴射する。

特開 2012-182131: 一方、近年では環境問題やエネルギー問題などの地球規模の課題を背景に、リチウム二次電池の車載用電源や定置型電源などの大型電源への応用にも大きな期待が集まっている。しかし、このような電池は一般に、長期に及ぶ充放電の繰り返しに対する安定性の確保が不可欠であり、さらには外気に晒される環境下での使用が見込まれているため、開発に当たっては氷点下のような低温環境下における電池特性、特に低温放電特性が重要視されている。

図2：日本文特許データベースの例




図3：図2の日本語特許から抽出された上位下位関係の例

2. 関連研究

2.1 上位下位関係の抽出

上位下位関係を抽出する代表的な手法は、定型表現を用いた手法である。安藤ら[19]は、7種の定型表現を利用し、新聞記事から名詞の下位語の自動抽出手法を提案している。難波ら[20]は、「などの」「のような」「といった」「等の」の4種類の定型表現を用いて日本語特許データベースから上位下位語を抽出している。直接上位下位関係にない用語対を検出される問題を解決するために、スコアの計算を導入している。同義語の区別をつけるために、引用分析手法を用いて同義語対の自動検出方法を提案している。上位下位関係を抽出する改善手法について、難波ら[21]は、分布類似度と定型表現を用いた手法を提案している。

Nanba ら[18]は、日本語と英語で記述された特許から定型表現を用いて上位下位関係の用語候補を抽出した後、統計的機械翻訳技術を用いて日英用語間の対応付けを行うことで、日英ソーラスを自動構築している。Nanba らの手法では、統計翻訳で対応付かない用語はすべて除外してしまっているが、本研究では、GANを用いることで翻訳の対応が付かないが正しい上位下位関係は多言語ソーラス内に残すこと、さらに、リンク予測モデルを用いて定型表現法では抽出できていない上位下位関係を検出することから、より網羅性の高い多言語ソーラスの構築が期待できる。

この他の多言語上位下位関係の検出の研究では、英語などの高リソース言語の上位下位関係の検出に主に焦点が当てられていた。Yu ら[4]は、低リソースの上位下位語を検出する問題に対処する。リソース不足の問題を解決するために、メタ学習を適用する手法を提案している。「言語横断トレーニング」、「多言語トレーニング」と「メタ学習」3つの共同トレーニングパラダイム方法を比較する。実験結果によって、3つの設定の中でメタ学習の方法が優れていることが示している。小規模なデータセットの過剰適合を防ぐことにより、リソースが非常に少ない言語のパフォーマンスを大幅に向上させる。Upadhyay ら[6]は、言語横断の上位下位関係検出のための教師なしアプローチ BISPARE-DEP 手法を提案している。バイリンガル embedding と教師なし含意スコアラーを利用し、上位下位関係を検出する。本研究と先行研究と異なる点は、定型表現で抽出した多言語の上位下位関係を一つのグラフとして、リンク予測モデルを

用いて各言語の欠落関係を自動補完する。

2.2 GAN を用いた上位下位関係分類器の構築

GAN を用いた従来の研究はデータの拡張、よりリアルな画像や文の生成などの目的で行われている。Kober ら[11] は、上位下位関係を検出ために、GAN を利用してデータを拡張する手法を提案している。この論文は既存の訓練データを利用し、新しい学習例を生成するデータ補強方法を検討している。言語学的な原理である上位下位関係の推移性と交差修飾語-名詞の構成を組み合わせ、上位下位関係が仮定できる。例えば、“small dog - dog” と “small dog - animal” のように、“animal” が dog の上位関係、“dog” が “small dog” の上位関係となった場合、“animal” が “small dog” の上位関係追加する。単語の適切な候補を見つけるために、名詞に修飾語を組み合わせる必要がある。実験結果によって、提案したデータ補強手法とデータセット拡張手法を利用し、分類器の性能を大幅に改善することを分かっている。Discriminator を分類器として利用する研究について、Chavdarova ら[16]は、SGAN という半教師あり GAN を提案している。SGAN を利用し、多クラス分類タスクを行う。本研究では、上位下位語の分散表現を GAN に入力し、学習済みの Discriminator を分類器として上位下位関係を識別する点が異なる。

2.3 リンク予測

近年、ディープラーニングは自然言語処理の数多くのタスクにおいて優れた成果を上げている。その理由はニューラルネットワークに関するモデルとアルゴリズムの進化を遂げている。多くのニューラルリンク予測モデルに関する研究が発表されている。Bordes ら[5]はディープラーニングにより知識グラフを低次元の空間に埋め込む TransE(Translating Embedding)モデルを提案している。Yang ら[7]は、関係行列を対角行列に制限するアルゴリズム DistMult(Bilinear Diagonal)を提案している。単純なバイリニア対角線を利用して、SOTA を達成することを示している。Trouillon ら[8]は、CompLex(Extension in the Complex Space)モデルを提案している。著者らは複雑な埋め込みを使用して、対称関係と反対称関係などの様々な2元関係を処理する。

ディープラーニングをグラフ形式で表現した構造データに関する研究が活発に行われている。構造データを扱うことができる GNN は 2016 年頃から大きな注目を集めている。GNN が扱う主な下流タスクは、リンク予測、グラフ分類やノード分類などが挙げられる。グラフ構造データに適用するために、Kipf ら[9]は、CNN の入力をグラフ構造に拡張できる GCN モデルを提案している。グラフ上で直接に操作できる畳み込みニューラルネットワークに基づいて拡張可能な教師あり学習アプローチを提案している。しかし、GCN はノード間の関係を考慮せずに、無視されている。GCN の問題点を解決するために、Schlichtkrull ら[10]は、

R-GCN(Relational Graph Convolutional Networks)モデルを導入し、ノード上のグラフ構造における異なるエッジ関係の影響に対処している。Jiang ら[15]は、リンク予測モデル ConvR を提案している。ConvR は、関係表現から畳み込みフィルターを構築し、このフィルターをエンティティ表現全体に適用し、畳み込み特徴を生成する。本研究では、リンク予測モデルとグラフ embedding 手法を結合し、多言語自動補完タスクに取り組んでいる。

3. GAN を用いた上位下位関係分類器の構築

本研究では、抽出した上位下位関係候補をフィルタリングための分類器の構築手法を提案する。特許から抽出した上位下位関係を WordNet で対応付けられたデータセットを作成し、GAN による上位下位関係を判定する分類器を構築する。分類器を用いて上位下位関係のグラフから不適切なノードを削除する。図4に、GAN による上位下位分類器の構築のアーキテクチャをまとめる。GAN は Generator と Discriminator の2つの要素から構成されている。Generator の役割はランダムな分布から偽物データを生成する。一方、Discriminator はデータが本物か偽物か識別する。本研究では、Discriminator に DeepWalk[12]から生成した単語 embedding を入力する。DeepWalk は、Perozzi らによって提案されたグラフの embedding 手法である。上位下位語をグラフのノードに変換して、DeepWalk でベクトル化する。各単語 200 次元を結合し、上位下位ペア 400 次元の embedding を生成する。Generator により与えられたノイズ Z から偽物データを生成する。Generator と Discriminator をお互いに競合して学習させる。最後に、学習済みの Discriminator を分類器として上位下位関係かどうかを分類する。GAN に対応付けられた多言語データセットを学習させる。上位下位関係ペアの候補を学習済みの分類器に入力して分類する。

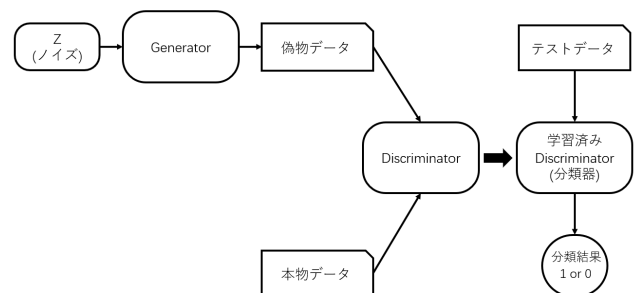


図4： GAN による上位下位分類器の構築

4. 多言語上位下位関係の自動補完

本研究では、ConvE と GraphSAGE を組み合わせた多言語上位下位関係自動補完手法を提案している。リンク予測タスクのための CNN モデル ConvE は単言語のリンク予測タスクに利用できるが、多言語のデータセットに利用する

のは容易ではない。この問題を解決するため、本研究では GraphSAGE を導入する。GraphSAGE は GNN におけるグラフ embedding の一手法である。グラフにおける GraphSAGE は近傍ノードの embedding を集約して、自身のノードの embedding を計算して更新する。ConvE はランダムな初期化値をノードの embedding とする。本研究では、DeepWalk を用いて、単語の分散表現を処理する。DeepWalk により各ノードの embedding を得られる。獲得された embedding をノードの初期化特徴量として使用されている。各ノードが 200 次元のベクトルを特徴量とする。WN18 の上位下位関係データセットを用いて提案手法の有効性を確認した。

図 5 にリンク予測モデルによる多言語上位下位語の補完システムの構築を示す。GraphSAGE は近傍のサンプルサイズ S とノードからの深さ K で範囲を指定している。本研究では、 $K=1$ 、 $S=5$ で設定されている。入力の特性ベクトル (s, r, o) を(上位語、上位下位関係、下位語)という形に変換し、上位下位関係をグラフのノードとして使用する。さらに、GraphSAGE によるソースノードの近傍ノードから情報を収集する。最後に、ConvE モデルを用いてソースノード 1 とターゲットノード 7 の欠落関係を予測する。欠落関係を予測する際、ソースノードからターゲットノードの関係を予測するだけでなく、ターゲットノードの隣接ノードを考慮して予測している。ソースノード 1 の近傍ノードとソースノード 7 の近傍ノードの間で対応付ける関係があれば、上位下位関係と判定される可能性が高い。次節で述べる実験では、各言語の上位下位関係を削除し、他の言語から欠落関係を予測する。




図 5: 提案手法による多言語上位下位関係のリンク予測

5. 実験

5.1 上位下位関係の抽出

実験データ

日本国特許は特許庁(<https://www.publication.jpo.go.jp/>)、中国語特許は J-Platpat(<https://www.j-platpat.inpit.go.jp/c1000/>)、米国特許は USPTO Bulk Data Storage System (<https://bulkdata.uspto.gov/>)からそれぞれデータを入手した。中国語特許の明細書に含まれている 1,148,250,436 文、日本語特許の明細書に含まれている 1,244,905,476 文と英語特許の明細書に含まれている 1,560,706,140 文のうち、頻度 3 以上の上位下位関係候補を抽出した。表 1 に、データの詳

細を示す。

表 1: 日英中特許から抽出した上位下位語関係の結果

特許データ	公開年	上位下位用語対
日本	1993-2018	2,908,574
米国	1993-2018	4,506,946
中国	2018, 2020, 2021	1,080,357

実験方法

Python のライブラリ spaCy の品詞解析を利用して、名詞 (NOUN) と固有名詞 (PROPN) のみを対象とする。各言語の定型表現を利用し、対象文から上位下位関係候補を抽出した。

実験結果

実験結果を表 1 に示す。各言語の定型表現を用いて日本、米国と中国語特許から計 8,495,877 件の上位下位候補を抽出した。

考察

各言語に誤って抽出した共通の原因は、抽出された上位下位語に余分な単語が含まれている。例えば、「酸化防止剤などの各種添加剤」という文に対して、「各種」を含む余分な単語が抽出してしまった。このような問題について、複数のパラメータを利用し、一致している用語対のみを抽出すると考えられる。

5.2 GAN による上位下位関係識別器の構築

実験データ

日英中特許から抽出した上位下位関係の中で Multilingual WordNet と対応が付けられた 3,794 件の多言語上位下位関係データを用いる。訓練データと評価データを 70% と 30% の比率で分割する。各言語に訓練データ 2,656 件、評価データ 1,138 件に分けている。

実験手法

GAN の実装は、PyTorch を用いて全結合ニューラルネットワークにより作成する。評価指標には、精度、再現率および F 値を用いる。

比較手法

GAN のフレームワークを使わずに、Generator を削除し、Discriminator のみで二値分類器を構築した。また、ロジスティック回帰による二値分類器を構築した。

実験結果

提案手法の分類結果と比較手法によって分類されている結果、を表 2 に示す。実験結果によって、提案手法は比較手法より高い精度、再現率と F 値が得られたため、提案手

法の有効性が確認された。

図 6 は、日本語で学習した際、GAN の Generator と Discriminator の損失関数の推移を示している。英語と中国語で学習した時の損失の推移は同様の傾向がある。GAN の訓練のプロセスは損失が振動しながら学習が進むが、学習過程が不安定になっていることがわかる。Discriminator の損失が抑えられる一方で、Generator の損失が大きくなっていく。

考察

日本語で得られた精度、再現率、F 値が英語と中国語より低い原因は、構築した日本語の用語リストに含まれる用語数が他の言語に比べ多いためであると考えられる。

表 2: 多言語データセットにおける上位下位関係を識別した場合の言語ごとの結果

手法	評価指標	日本語	中国語	英語
Logistic Regression	精度	0.841	0.864	0.873
	再現率	0.524	0.644	0.645
	F 値	0.645	0.738	0.742
CNN (Discriminator)	精度	0.841	0.840	0.861
	再現率	0.469	0.529	0.584
	F 値	0.602	0.649	0.696
GAN (Generator + Discriminator)	精度	0.866	0.872	0.875
	再現率	0.875	0.917	0.936
	F 値	0.871	0.894	0.905




図 6: 日本語で学習した時の損失関数の推移

5.3 多言語自動補完システムの構築

実験データ

表 3 に示す比較実験では、WN18 データセットの上位下位関係のみ(合計 18 の関係) 74,442 件のデータを利用した。

表 4 に示す実験では、日英中特許用語のうち、WordNet にも存在する上位下位関係 6,231 件を利用した。用語間の関係には(is a hypernym, is not a hypernym, alignment)の 3 種類が存在する。言語ごとにデータセットを訓練用 46,109 件、検証用 9,970 件、評価用 9,242 件に分割した。

実験手法

PyTorch Geometric で ConvE モデルを構築し、GraphSAGE を導入する。評価指標には、MRR、H@1、H@3 と H@10 を用いる。

比較手法

Dettmers ら[1]により提案された ConvE と Jiang ら[15]により提案された ConvR を比較手法とする。

実験結果

本研究で提案する手法 ConvE+GraphSAGE を用いた上位下位関係を予測された結果と比較手法によって予測された結果を表 3 に示す。実験結果によって、H@1、H@10 と MRR の評価指標において本研究で提案する手法が優れていることが分かっている。提案手法の有効性が確認した。自動補完実験の結果を表 4 に示す。H@1 と MRR の評価指標において英語が他の言語を上回る結果を出すことが分かっている。H@3 と H@10 の評価指標において中国語が他の言語を上回る結果となった。

考察

日本語で得られた MRR が英語と中国語より低い原因は、グラフの中に切り離しノードの数が多いと思われる。GraphSAGE を用いたノードの embedding を計算した際、近傍のノードの数が不足している。今後は、切り離しノードの数を減らすことで、MRR を向上させることができると考えられる。

表 3: WN18 上位下位関係データセットにおける上位下位関係を予測した場合の H@k および MRR の結果

手法	H@1	H@3	H@10	MRR
ConvR	42.9	49.3	55.4	47.5
ConvE	44.7	81.4	90.1	64.0
ConvE+GraphSAGE	52.3	80.1	90.2	67.1

表 4: 多言語データセットにおける上位下位関係を
予測した場合の言語ごとの H@k および MRR の結果

手法	評価指標	日本語	中国語	英語
ConvE + GraphSAGE	H@1	29.4	25.2	35.0
	H@3	62.3	71.4	65.5
	H@10	92.0	97.3	90.4
	MRR	49.4	50.1	53.3

6. おわりに

本研究では、多言語定型表現を用いて日本語、英語と中国語の特許データから上位下位関係を抽出し、Multilingual WordNet との対応付けにより多言語上位下位関係データセットを作成した。GAN を用いた学習済みの Discriminator を利用し、上位下位関係を識別できる分類器を構築した。英語で再現率 0.936 を達成した。CNN リンク予測モデル ConvE と GNN アルゴリズム GraphSAGE を組み合わせ、欠落上位下位関係を自動補完できる新たな手法を提案し、中国語で H@10 指標 97.3 を達成した。今後は Multilingual BERT や XLM-RoBERTa などの多言語モデルを使用した embedding を組み込むことで、提案手法がどの程度改善されるか検討する。

謝辞 本研究は JSPS 科研費 22K12154 の助成を受けたものである。

参考文献

- [1] Dettmers, D., Minervini, P., Stenetorp, P., and Riedel, S., Convolutional 2D knowledge graph embedding, Proceedings of the 32th AAAI Conference on Artificial Intelligence, 2018.
- [2] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. and Bengio, Y., Generative Adversarial Nets. Proceedings of the 27th International Conference on Neural Information Processing Systems, pp.2672-2680, 2014.
- [3] Huang, Z., Li, Z., Jiang, H., Cao, T., Lu, H., Yin, B., Subbian, K., Sun, Y., and Wang, W., Multilingual Knowledge Graph Completion with Self-Supervised Adaptive Graph Alignment. Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics, pp.474-485, 2022.
- [4] Yu, C., Han, J., Zhang, H. and Ng, W., Hypernymy Detection for Low-Resource Languages via Meta Learning. Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, pp.3651-3656, 2020.
- [5] Bordes, A., Usunier, N., García-Durán, A., Weston, J. and Yakhnenko, O., Translating Embeddings for Modeling Multi-relational Data. In Proceedings of NIPS, pp.2787-2795, 2013.
- [6] Upadhyay, S., Vyas, Y., Carpuat, M. and Roth, D., Robust Cross-lingual Hypernymy Detection using Dependency Context. The 16th Annual Conference of the North American Chapter of the Association for Computational Linguistics, pp.607-618, 2018.
- [7] Yang, B., Yih, W., He, X., Gao, J., and Deng, L., Embedding Entities and Relations for Learning and Inference in Knowledge Bases. In Proceedings of ICLR 2015, 2015.
- [8] Trouillon, T., Welbl, J., Riedel, S., Gaussier, É. and Bouchard, G., Complex Embeddings for Simple Link Prediction. In Proceedings of ICML 2016, pp. 2071-2080, 2016.
- [9] Kipf, T.N. and Welling, M., Semi-Supervised Classification with Graph Convolutional Networks. arXiv preprint arXiv:1609.02907, 2016.
- [10] Schlichtkrull, M., Kipf, T. N., Bloem, P., Berg, R. v. d., Titov, I. and Welling, M., Modeling Relational Data with Graph Convolutional Networks. arXiv preprint arXiv:1703.06103, 2017.
- [11] Kober, T., Weeds, J., Bertolini, L. and Weir, D., Data Augmentation for Hypernymy Detection. Proceedings of the 16th Conference of the European Chapter of the Association for Computational Linguistics, pp1034-1048, 2021.
- [12] Perozzi, B., Al-Rfou, R. and Skiena, S., DeepWalk: Online Learning of Social Representations. Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining, pp.701-710, 2014.
- [13] Hearst, M. A., Automatic Acquisition of Hyponyms from Large Text Corpora, in Proceedings of the 14th International Conference on Computational Linguistics, pp.539-545, 1992.
- [14] Chen, X., Chen, M., Fan, C., Uppunda, A., Sun, Y. and Zaniolo, C., Multilingual Knowledge Graph Completion via Ensemble Knowledge Transfer, In Findings of the Association for Computational Linguistics: EMNLP 2020, pp.3227-3228, 2020.
- [15] Jiang, X., Wang, Q. and Wang, B., Adaptive Convolution for Multi-Relational Learning, In Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics, Vol. 1, pp.978-987, 2019.
- [16] Chavdarova, T. and Fleuret, F., SGAN: An Alternative Training of Generative Adversarial Networks, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition 2018, pp. 9407-9415, 2018.
- [17] Hamilton, W.L., Ying, R. and Leskovec, J., Inductive representation learning on large graphs, Proceedings of the 31st International Conference on Neural Information Processing Systems, pp.1025-1035, 2017.
- [18] Namba, H., Mayumi, S., and Takezawa, T. Automatic Construction of a Bilingual Thesaurus using Citation Analysis. Proceedings of the 4th International CIKM Workshop on Patent Information Retrieval (PaIR'11), pp.25-30, 2011.
- [19] 安藤まや, 関根聡, 石崎俊, 定型表現を利用した新聞記事からの下位概念単語の自動抽出, 情報処理学会研究報告 2003(98), pp.77-82, 2003.
- [20] 難波英嗣, 奥村学, 新森昭宏, 谷川英和, 鈴木泰山, 特許データベースからのシソーラスの自動構築, 言語学処理学会年次大会発表論文集 13th, pp.1113-1116, 2007.
- [21] 難波英嗣, 定型表現法と分布類似度を用いた特許データベースからの用語の上位、下位関係の抽出, JAPIO year book 2017, pp.226-228, 2017.