大学共同利用機関法人 情報・システム研究機構
国立情報学研究所
National Institute of Informatics

トップエスイー ソフトウェア開発実践演習

論文の内容における特徴量を用いた高引用論文の早期発見に向けて

川島大樹(株式会社NTTデータアイ)　来間一郎(株式会社日立製作所)　新田佳菜(株式会社東芝)

高引用論文発見の問題点

価値が高い(被引用数が高い)論文の早期発見
①公開論文数増加により、自力で価値の高い論文を見つける難易度が高まった
②従来の被引用数予測では「過去1～2年の被引用数実績」を特徴量として扱っていた

手法・ツールの適用による解決

①被引用数予測に必要な情報を自動抽出する
②論文の内容から得られる情報(特徴量)だけで将来の被引用数を予測できるようになる

既存特徴量・新規特徴量

既存特徴量(被引用数以外)

表層的な情報がほとんどで、内容の良し悪しが反映されない

- 著者数
- 所属機関数
- 参照文献数
- 参照文献の新しさ
- ページ数
- キーワード数
- タイトル中のコロン区切り有無
- タイトルの文字数
- アブストラクト中の文字数
- 本文中の図表の数　　etc…

提案する新規特徴量

論文の内容理解に踏み込んだ特徴量として、
「背景・課題 の 理解しやすさ」など，4x4=16通りの特徴量を定義

論文内セクション	×	良い論文の指標	
背景・課題		理解しやすさ	簡潔明瞭に整理
提案手法		情報の十分性	妥当性評価や再現に十分な情報
評価手法・データ		新規性	既存研究にない着眼点や手法
結果・考察・結論		重要性	重要な社会課題の解決に寄与

→ 特徴量の定義と論文テキストを入力として、GPT-4を用いて定量化

予測精度の評価結果

A. 既存特徴量	B. 既存特徴量 + 新規特徴量
0.4921917	**0.5137554**

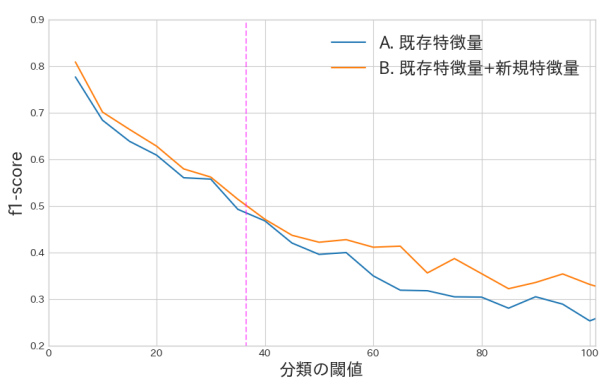

Random Forestを用いた分類モデルで高引用論文を予測した結果、**新規特徴量追加により精度が改善**
→新規特徴量のスコアについても概ね妥当であった

考察・課題

■ **新規特徴量追加により、予測精度は僅かに改善**
　○　新規特徴量は予測に有用と考えられる

■ **予測精度としてはやや不十分な結果**
　○　学習データや特徴量の追加によって更なる予測精度の改善が見込める
　○　予測タスク自体の難度が高かった可能性も

■ **今後の課題**
(1) 別の分析手法を用いる
(2) 別の特徴量を用いる
(3) 専門家によるLLM算出スコアの妥当性確認
(4) モデル予測精度不良の原因の深掘り