

宇宙物理学文献データベースADSからの情報抽出

トラン ヴァン ディエン, 天笠 俊之, 北川 博之 (筑波大学)

協力：海老沢研氏, 中平聡志氏 (JAXA)
大石雅寿氏, 市川伸一氏 (国立天文台)

背景：学術文献データベースとその活用

学術文献データベース

- 学術論文, 書籍等の文献情報およびテキスト情報を含むデータベース.
- 代表的な文献データベース.



ADS (The SAO/NASA Astrophysics Data System)

- 天体物理学分野の文献データベース.
- 1995年から運用.
- 物理学, 天文学, 天体物理学の990万件以上の文献情報を含む.

学術文献データベースの活用

- 学術文献データベースから, 有益な情報を抽出することが可能.

リンク構造解析

- 文献 (研究者) の重要度のランキング: PageRank, ObjectRank等

クラスタリング

- 文献 (研究者) の分類: 最大マージンクラスタリング [Nguyenら]

自然言語処理

- 研究動向の抽出: 自然言語パターン解析 [難波ら]
- 複数の分野を含む場合, 単一のランキングでは不十分**
→ **ランキングとクラスタリングの併用**

研究の目的：ADSからの情報抽出

- クローラの設計, 実装
- 文献データベースからの情報抽出 (RankClusの適用)

ADSクローラの設計と実装

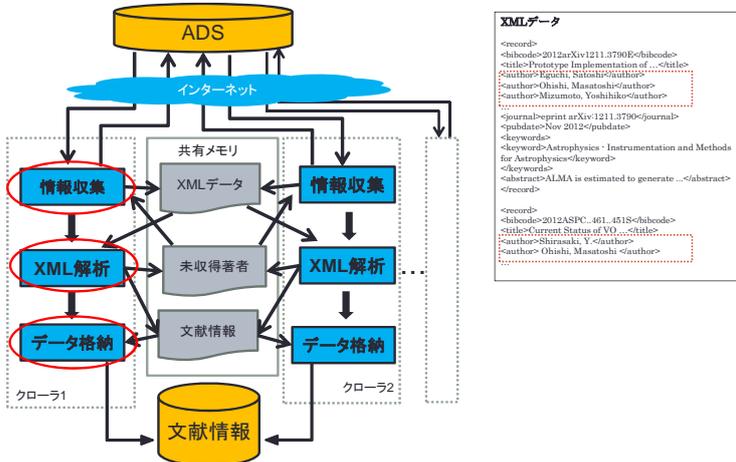
ADSのデータは一括ダウンロード不可

→ クローラによるデータ取得が必要

クローリングの方針

- Web APIの利用.
 - 著者を指定しXML形式でデータを取得可能
- 少数の著者をシードとして, 再帰的に共著者を取得.

クローラの概要



取得済みデータ (クローリング継続中)

- 著者数: 167,704
- 文献数: 2,665,166

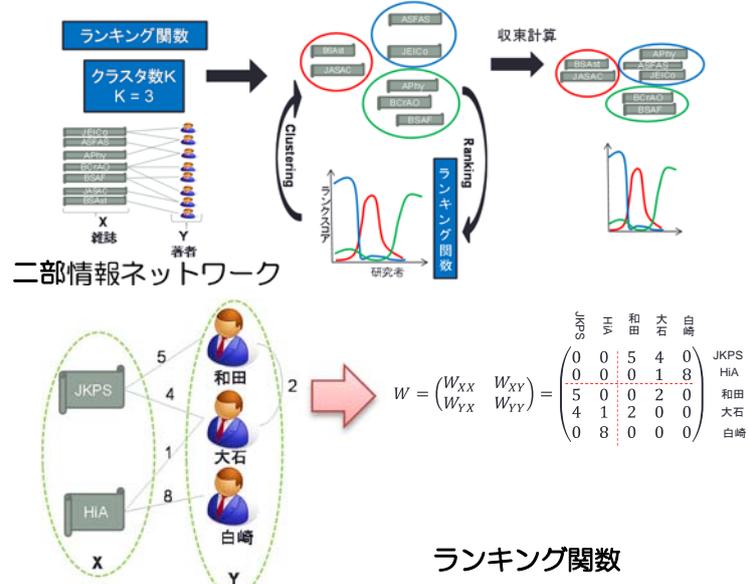
文献ID	タイトル	キーワード	概要	リンク
2012ASPC..461..451S	Current Status of ...	Null	In these years, standards ...	http://...;
2012ASPC..461..375K	VO Crawler...	Null	We report on the...	http://...;
2012PASA...29..229H	The Completeness and ...	data analysis, radio ...	The process of determining...	http://...;

文献ID	研究者ID	研究者ID	研究者の名前
2012ASPC..461..451S	1190	1190	Shirasaki, Y
2012ASPC..461..451S	1191	1191	Komiya, Y
...
2012PASA...29..229H	1250	1250	Huynh, M. T

RankClusによる情報抽出

RankClusの概要

- 二部情報ネットワークが対称.
- クラスタリングとランキングを交互に実行.



Authority rank

$$\vec{r}_Y(j) = \alpha \sum_{i=1}^m W_{YX}(j, i) \vec{r}_X(i) + (1 - \alpha) \sum_{j'=1}^n W_{YY}(j, j') \vec{r}_Y(j')$$

$$\vec{r}_X(i) = \sum_{j=1}^n W_{XY}(i, j) \vec{r}_Y(j)$$

結果

- 3分野34雑誌をランダムに抽出 (著者数6,261)

