

ROIS-DS人文学オープンデータ共同利用センター：「データ駆動型人文学」と「人文学ビッグデータ」の展開

情報・システム研究機構 データサイエンス共同利用基盤施設 人文学オープンデータ共同利用センター (CODH)

北本 朝展、小川 潤、加藤 幹治 (NII) / 市野 美夏、王 小醒 (ISM)

どんな研究？

- データ駆動型人文学：情報学・統計学の最新技術を用いて人文学資料（史料）を分析
- 人文学ビッグデータ：人文学研究の成果に基づき構築したデータセットを超学際的に活用
- 人文学のデジタル変革：オープンサイエンスなど新しい潮流を取りこんだ人文学研究へ

何がわかる？

- データ駆動型研究を進めるための、機械可読データセットを構築・公開
- オープンソースソフトウェアを公開し、各種のサービスを外部からも活用
- 共同研究を通して知識や資源を提供

背景・目的




データサイエンス共同利用基盤施設 (DS) は、情報・システム研究機構 (ROIS) 内に設置された研究組織。生命科学・地球科学から人文学・社会科学まで、データサイエンスを幅広い分野で推進する6つのセンターがある。



人文学者や情報学者などが分野横断的に協働し、人文学的な問い合わせ情報を学的な手法で解く、人文学資料から作る過去のビッグデータを分析する、などの研究に取り組む。人文学的な視点は、AIなどのテクノロジーを社会に取り入れるためのガイドとしても重要になりつつある。


研究内容

AIくずし字認識アプリ「みを」




- 物体検出アルゴリズムを用いて、画像からくずし字を認識し、現代日本語文字に変換。
- iOS・Androidアプリを無料で公開、ダウンロードは10万回以上！
- これまでの認識画像枚数は約150万枚。教育や調査に幅広い利用実績。

歴史的日本語データセット



- AIくずし字認識を大規模化し、江戸時代以前の過去の書籍や文書から大量のテキストを抽出。
- 大規模言語モデル等のための機械学習データセットとして公開。
- 全文検索やテキスト分析など、日本文化のビッグデータとして利用。

IIIFキュレーションと「顔コレ」



- IIIF (International Image Interoperability Framework) のためのオープンソース基盤IIIF Curation Platform (ICP)を開発。
- 日本美術から「顔」の部分画像を切り出して、作品横断的なコレクションを構築。
- 美術史研究の大規模化や検証可能性を開拓。

歴史ビッグデータ



- 過去の資料から構造化データを抽出し、現代のビッグデータ技術を活用して過去を復元。
- 時空間復元のための地理識別子を重点的に整備。
- データ構造化ツール、データ公開サイトなどの連携を推進。
- 古地震や古気候などの分野で、実世界データを検証。