

観るアーカイブから組み合わせ、
計算するアーカイブへ
—データ駆動型研究を支える次世代の基盤づくり—

講師：吉賀 夏子(人文学研究科・人文学林)

2026年2月13日

大阪大学附属図書館（豊中キャンパス）



本日のメニュー

- 第1部:はじめに
- 第2部:研究者の現場:データへの渴望
- 第3部:人文学の壁とクローズドの価値
- 第4部:次世代の基盤:存在証明と責任共有
- 第5部:むすび

【第1部】はじめに

自己紹介

吉賀夏子(よしがなつこ) (大阪大学大学院人文学研究科)

<https://researchmap.jp/ny5>

専門: Digital Humanities (DH、人文情報学)

アカデミックバックグラウンド:

情報学(データベース・セマンティックウェブ) / 農学(線虫学)

主な講義:

研究科共通科目(2023年～)

「デジタルヒューマニティーズ基礎」

「デジタルヒューマニティーズ演習」



デジタルヒューマニティーズ =ダイナミックな「方法論の共有地」

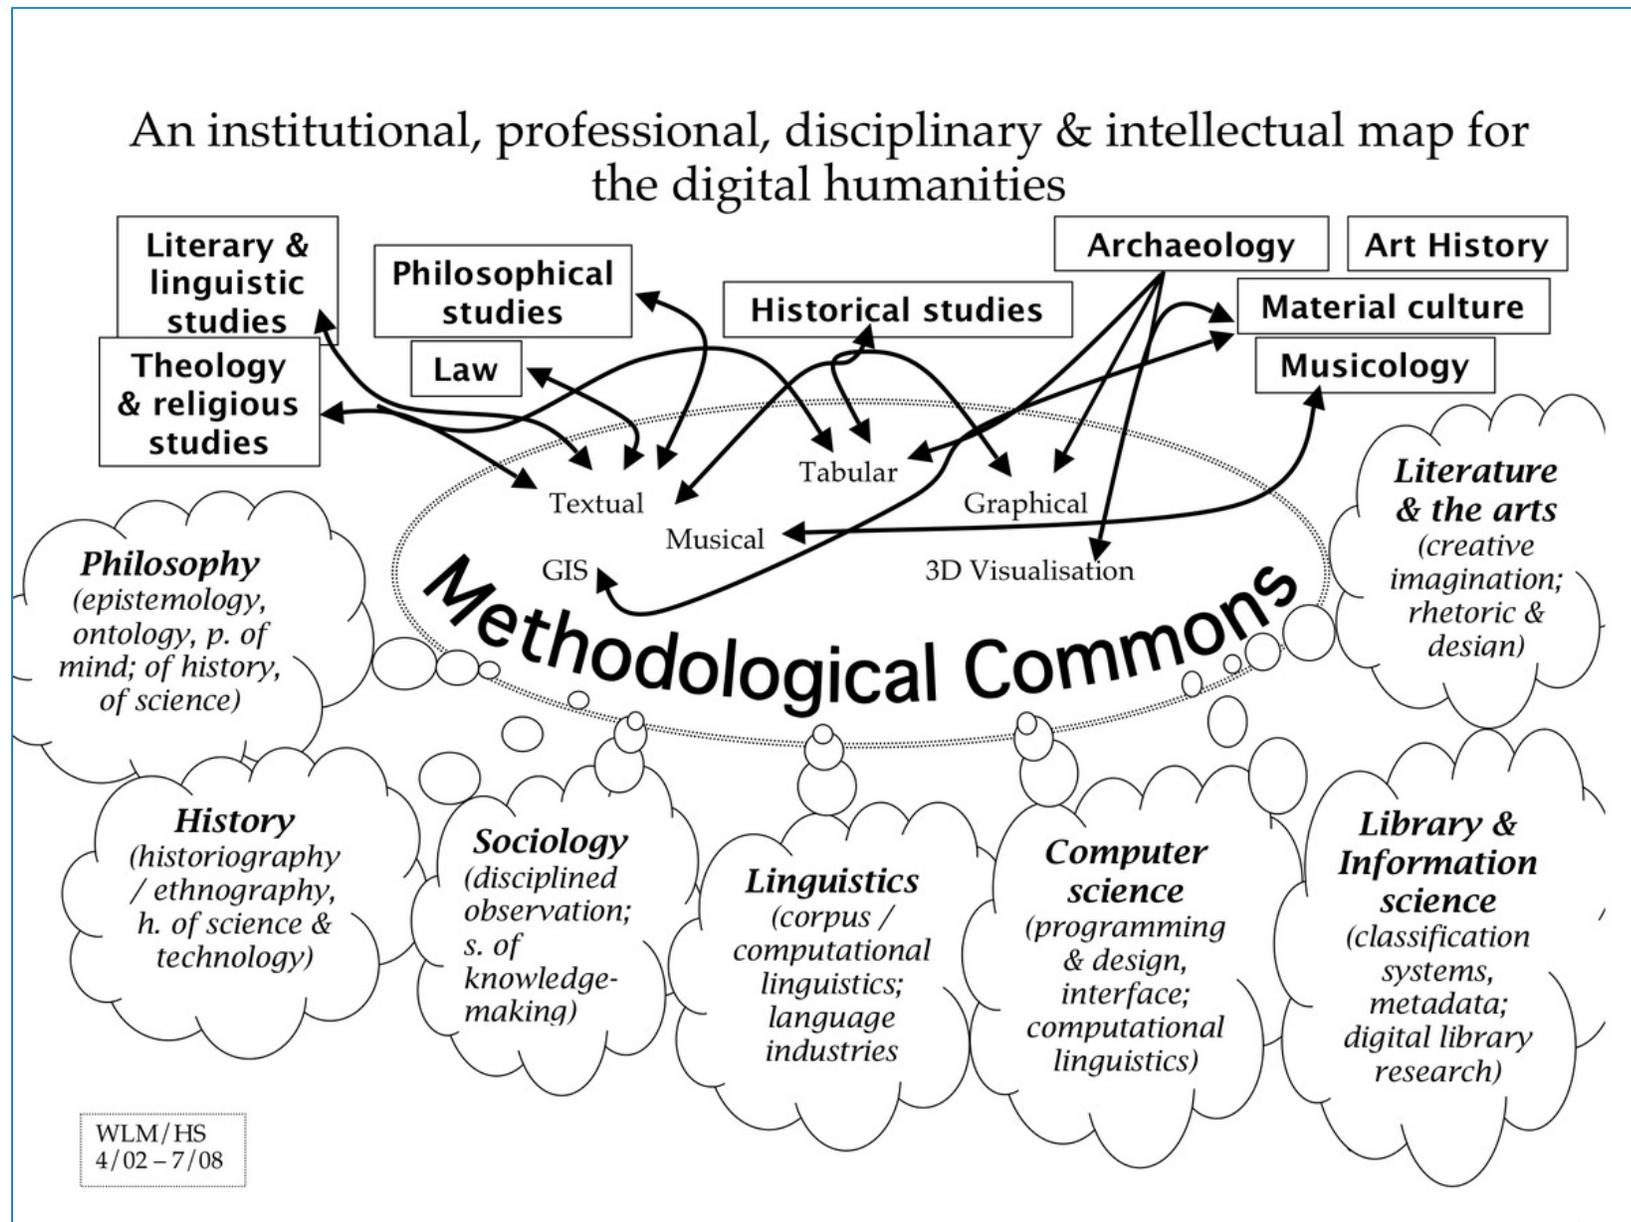
文系、理系、あらゆる方向性の学問をつなぎ、新たな知を生み出す方法を論じる学問。

特に**情報学**の力で人文社会科学の**価値**を向上させる。



Methodological Commons [1] (方法論の共有地の) イメージ図

- 様々な学問分野で使える共通の「方法論の広場」あるいは「ポットラックパーティー」のようなイメージ。



DH実践例1: 十番虫合絵巻(ホノルル美術館所蔵)

<https://juban-mushi-awase.dhii.jp/index.html>



天明2年(1782)8月に、江戸の木母(もくぼ)寺で、幕府旗本の主催で行われた「十番虫合」という雅びな催し

参加者は左右に分かれ、**鈴虫と松虫**に草花などを使って趣向を凝らした**飾り台**を展示し、それにちなんだ和歌を詠んで競い合う

飾り台の例



Juban Mushi-awase Emaki

Left ¹ Bell cricket Right Pine cricket
 Judge for the insect arrangements ² Chikage
 Judge for the poems ³ Suetaka

Round 1

Left ⁴ Toshinari

It is not when rain falls, but right when crickets trill that it becomes a scene to behold— ⁵ this canopy of bush clover!

Right ⁶ Suetaka

In which autumn was it that the melody of a jewel-like koto first came to be likened to notes of the pine cricket?

The arrangement on the Left takes its inspiration from ⁷ “You people who are serving [the lord], offer him a canopy.” Fashioning the stand with a rust-colored hunting cloak sleeve, they use a court cap of state as the insect’s cage, and on top of a branch of bush clover, they

Footnote:

¹ In present-day Japanese, the *suzumushi* (bell cricket) refers to *Meloimorpha japonica*, while the *matsumushi* (pine cricket) refers to *Xenogryllus marmoratus*. (Both belong to the order Orthoptera.) Evidence is strong that in the Heian period, the nomenclature was reversed, so that what we now call the “suzumushi” was then called “matsumushi,” and vice versa. However, for the purposes of this event, taxonomy is less important than literary

(ダブルクリックで同期移動)

左 利徳
 一番 虫判 千蔭
 歌判 季鷹

右 季鷹

雨ならでふりつつ虫の鳴くなへにきてもみるべく萩が花笠

王琴のしらべにいつの秋よりかまつ虫の音もかよひ初めけむ

左は、「みさぶらひみ笠とまうせ」といへる心ばへして、朽葉色の狩衣の袖を台にて、烏帽子を虫籠にして、白銀の笠を萩がもとにおけり。虫は宮城野よりえらみて参らせたるなり。右は、亭子院

左 利徳
 一番 虫判 千蔭
 歌判 季鷹

雨ではなくて、露を振り払いながら、鈴虫の鳴くちようどその時に、来て見るのがよい。花笠のような萩の花を。

左の作りものは、「みさぶらひみ笠と申せ宮城野のこの下露は雨にまされり」という趣向で、朽葉色の狩衣の袖を台にして、烏帽子を虫籠にして、銀の笠を萩のかたわらに置いた。鈴虫は、宮城野から選んで用意申し上げました。右の作りも

IIIF画像

閉じる

『十番虫合絵巻』



画像表示

ICViewer Embedded | Honolulu Museum of Art

『十番虫合絵巻』

和歌 人物

源 蔭政

蔭政

○「十番虫合」の饗応役（主催者）。跋文に出る。十番右歌作者。

英訳 現代語訳

ローマ字ルビ

使用されている便利な仕組み

TEI (ティーイーアイ、Text Encoding Initiative)

- テキストに目印(タグ)をつけて、ブラウザで思い通りの表示ができるようにする、人文学研究者とそのコミュニティ主導の国際的なガイドラインと技術を提供している。

IIIF (トリプルアイエフ、International Image Interoperability Framework)

- ブラウザだけでIIIFの定める形式に沿った画像を表示できる国際的なルールを提供する。Google Mapのような手軽さで、高精細な画像やモニターで表示しにくい巻物なども難なく表示できる。
- 異なる館・組織の画像もIIIF形式なら、同じブラウザ画面に並べて表示できる。

DH実践例2:「みんなで翻刻」「KuLA」

<https://honkoku.org/>

翻刻:日本の文書、記録、古典籍などの画像からテキストを抜き出すプロジェクト

- くずし字という専門知識を要するが、AIの支援と学習機能(KuLA)で市民の「解釈」を助ける。
- 2017年に歴史地震の研究グループである[京都大学古地震研究会](#)による、地震史料の翻刻プロジェクトを始めたのがきっかけ。
- くずし字学習支援アプリ「KuLA」も合わせて開発
- https://www.let.osaka-u.ac.jp/ja/research/community/hodo/iikura_KuLA
- 2016年に大阪大学飯倉洋一先生を中心に開発されたモバイルアプリ



【左丁】

貴船権現端権殿並びに奥社等への御日供（各同前の通り）

- 一 御箸 一組 一 御飯 二杯
- 一 御団子 一杯 一 御餛 一杯
- 一 御平切 一杯 一 御細切 一杯
- 一 御鱈 一杯 一 御焼物 一杯

【右丁】

この翻訳はAIにより自動生成したものです。誤りが含まれる可能性がある程度に留めてください。

貴布禰端権殿 《割書》 并 《奥社等御日供》 《割書》 各同前

- 御箸 一具 御飯 二杯
- 御団子 一杯 御餛 一杯
- 御平切 一杯 御細切 一杯
- 御鱈 一杯 御焼物 一杯
- 御酒 一杯

【右丁】

御餛 二杯

御団子 二杯

御神酒 二杯

原文のテキスト入力だけでなく、
現代日本語訳や英訳まで自動！！



「みんなで翻刻」操作画面

DH実践例3:「みんなで翻刻」とのタイアップ イベントでOUKA所蔵資料を利用

「べらぼう」関連資料を使った翻刻チャレンジと異分野交流イベント
(2/16(月)対面開催予定)

<https://forms.office.com/r/s7Qf9JL40N>



- AI-OCRを使って下書き、くずし字勉強会で学習中の大学院生と一緒に翻刻
- NDL OCR LiteとMetom (Sakana AI) による自動翻刻
- 「みんなで翻刻」機能で、翻刻した文を現代日本語訳および英訳で書かれている意味も推測できる

OUKAの例1:「懐徳堂」インデックスサイト

<https://ir.library.osaka-u.ac.jp/portal/kaitokudo/>



OUKAの検索画面とは別に、リポジトリのリンクと附属図書館提供の書誌データを使って特設サイトを開設

書誌ID	書名／出版者等詳細	著者名	寄与者	出版年／ハンドルURL	
	履軒古韻	中井履軒			https://hdl.handle.net/11094/93922 画像を閲覧する manifest
	写本 / 〈序〉明和7年履軒幽人序。〈伝〉(印記)「懐徳堂圖書記」「履軒図書」「天生寄進」。〈書〉帙に「履軒手稿 / 〈序〉明和7年履軒幽人序。〈伝〉(印記)「懐徳堂圖書記」「履軒図書」「天生寄進」。〈書〉帙に「履軒手稿」				
	履軒先生對月帖	中井履軒			https://hdl.handle.net/11094/93957 画像を閲覧する manifest
	刊本 / 〈序〉文化1年跋。〈形〉折本。〈伝〉(印記)「財団法人懐徳堂記念会印」他1印。				
2004305903	學庸雕題	中井履軒			https://hdl.handle.net/11094/94021 画像を閲覧する manifest
	[中井積徳][自筆] 写本 / 書名は『懐徳堂圖書目録』による / 『大學』の序の書名: 大學章句 / 『中庸』の序の書名: 中庸章句 / 中井履軒自筆首書 / 『七經雕題』之一 / 印記: 「積徳」、「履軒圖書」(2印とも中井履軒)、「天生寄進」、「懐徳堂圖書記」				
2004305904	論語雕題	中井履軒			https://hdl.handle.net/11094/94022 画像を閲覧する manifest
	[中井積徳][自筆] 写本 / 書名は『懐徳堂圖書目録』による / 中井履軒自筆首書 / 『七經雕題』之一 / 印記: 「履軒圖書」(中井履軒)、「天生寄進」、「懐徳堂圖書記」				

OUKAの例2:OUKAの研究成果の公開支援

- 大阪大学の教育研究活動から生み出される論文などの学術成果を電子的に保管・公開するサービス。
- リポジトリに自分の論文を登録・公開できる。
- 検索サイトでヒットしやすくなる。
- リンクひとつで他の研究者に自分の論文を紹介しやすくなる。



大阪大学オープンサイエンス推進室
研究データ管理・オープンアクセス支援

お問い合わせ



研究計画とデータマネジメント



研究データの取得・収集・保存・解析



研究成果の公開と利活用

OUKAとは

大阪大学学術情報庫 OUKA(The University of Osaka Institutional Knowledge Archive) は大阪大学の機関リポジトリです。大阪大学の教育研究活動から生み出される論文などの学術成果を電子的に保管・公開するサービスです。本学に所属する研究者は学術成果を公開することができます。登録にあたって費用負担の必要はありません。公開されたコンテンツは誰でも無償で閲覧できます。このようなサービスを機関リポジトリと言い、インターネットを通じて世界中の誰もが、いつでも大学などの学術成果を自由に無料で見られるようにすること(オープンアクセス)を目的に構築されています。

OUKAで公開するメリット

- OUKAに登録されたコンテンツは、Google ScholarやCiNiiなどの外部データベースからも検索可能になり、学術成果の可視化向上に役立ちます。
- 出版社にAPCを支払う必要があるゴールド・オープンアクセス(オープンアクセス出版)とは違い、著者に費用負担が生じません。

<https://osoa-portal.osaka-u.ac.jp/research-disclosure/ouka-oa/>

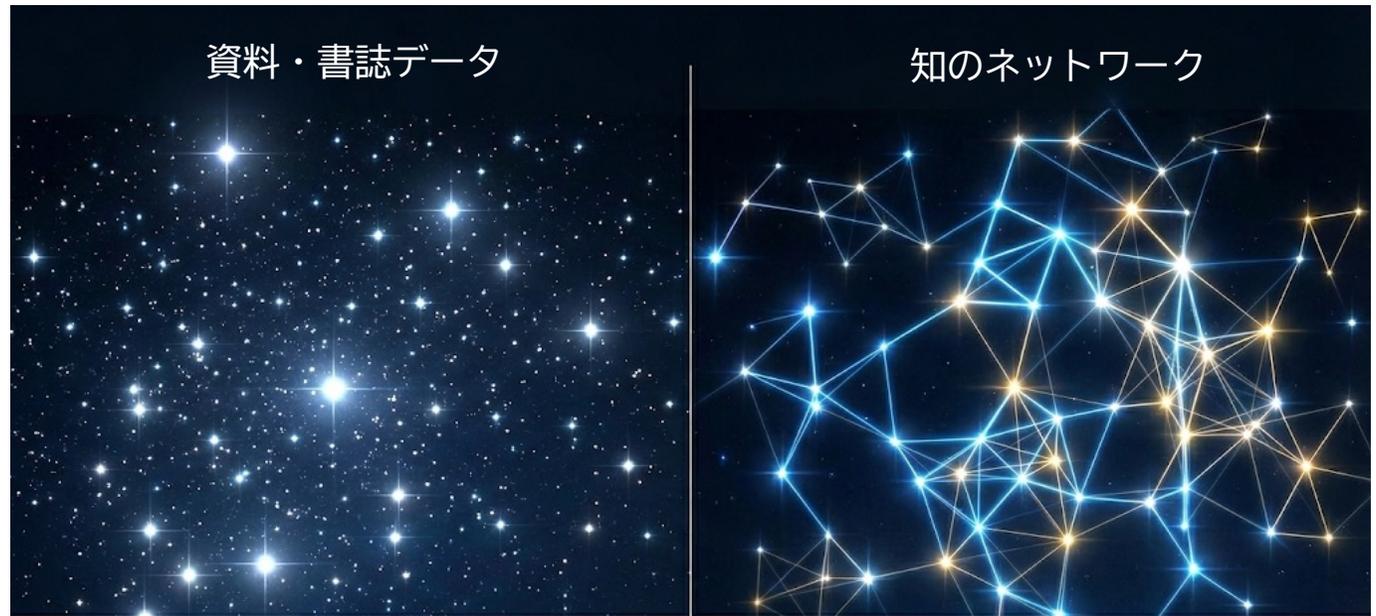
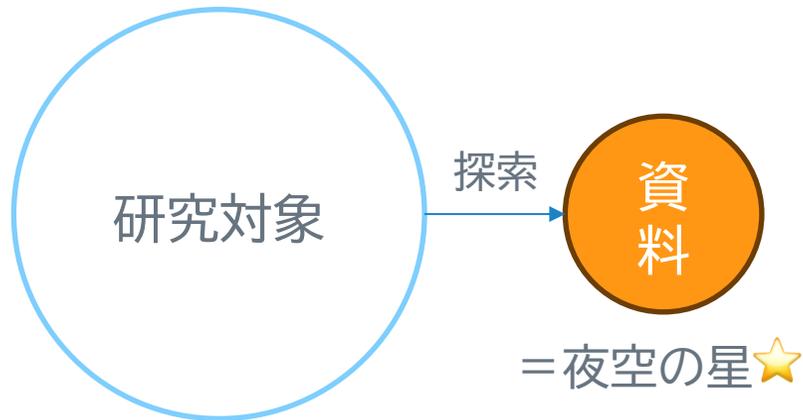
第一部まとめ

- 図書館は、資料をデジタル化し、世界中どこからでも「アクセス可能」にしました。
- DHは、その恩恵を受け、人文学・社会科学の研究スタイルを大きく進化させてきました。
- そして今、私たちは次のフェーズにいます。
資料を単に参照するだけでなく、**計算資源**として使い倒すための次世代の基盤を、皆さんと一緒に考えたいと思います。

【第2部】研究者の現場：データへの渴望

研究者はデータをどう「見て」いるか

研究の時は、史資料を一枚ずつ吟味するというよりは、数千、数万の資料をプログラムに読み込ませて、**一気に傾向やつながり**を分析したいと思っている。



図書館の視点：正確な「点」を管理する。

研究者の視点：点と点をつないで線（関係性）を計算する。

例えばNDLで書誌データを取得する🪣

手順1: 蛇口(API)の前に、バケツ🪣を置いてリクエスト(注文)を投げる

- 研究者は、ブラウザの検索窓にキーワードを入れる代わりに、Pythonなどのプログラムから「クエリ(命令文)」をNDLのサーバーに直接投げます。
 - 接続先(蛇口🪣の場所):
<https://ndlsearch.ndl.go.jp/api/sru>
 - 今回の注文内容(クエリ):
「江戸時代の文学(NDC 913あたり)」「デジタル化されているもの」「100件～500件まとめてくれ」

手順2: データで返ってくる(水💧=データが出る)

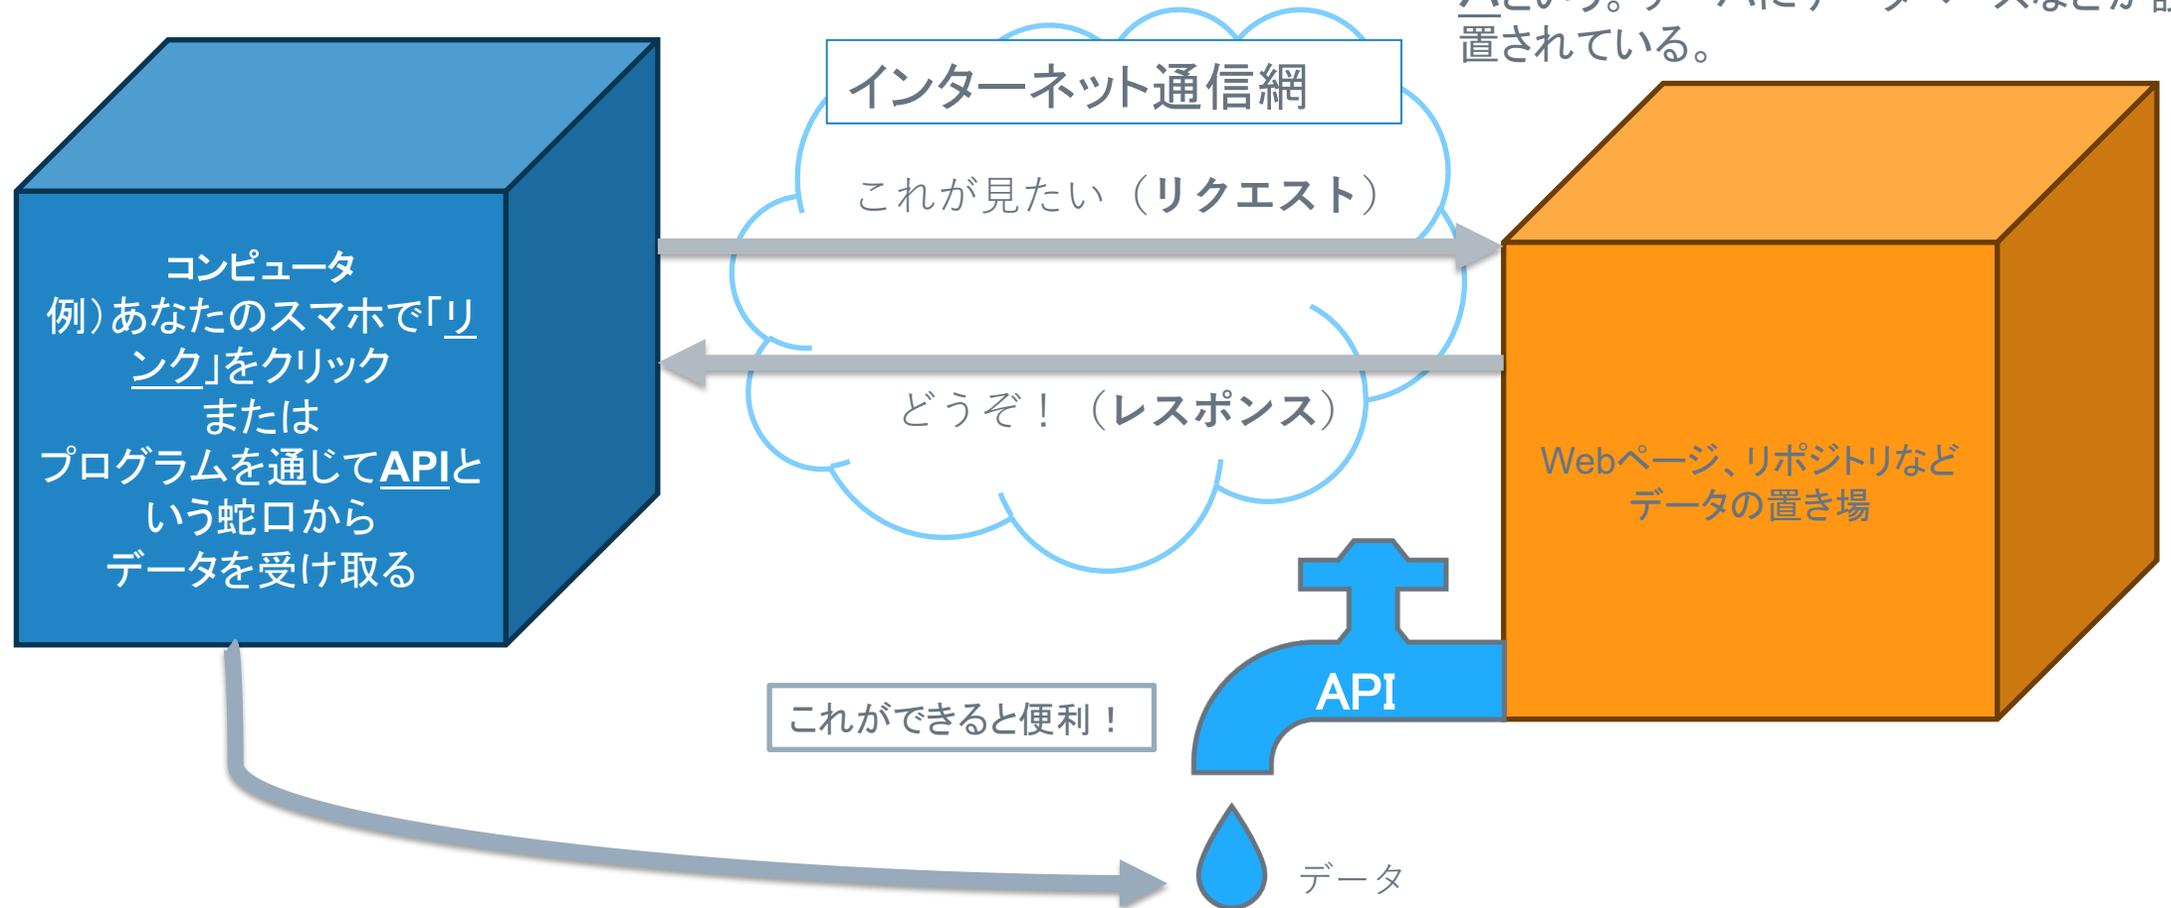
NDLのサーバーは、画面ではなく、データで応答します。
ここには、書名、著者名、出版者、サイズ、DOIなどの情報がぎっしり詰まっています。

手順3: 水💧を用途に合わせて使う: CSVなどに変換する

返ってきたデータは人間には読みづらいため、Pythonプログラムで必要な項目(タイトル、著者、正規化IDなど)だけを抜き出し、Excel等で開けるデータ形式に変換します。

つまり、APIはプログラムを使ってデータベースの蛇口を回す手段

欲しいデータを配信するコンピュータをサーバという。サーバにデータベースなどが設置されている。



ヒットしたデータをどうするか？（前処理の壁）

APIを使えば、数千件の書誌データを一瞬で手元に持ってくるることができる。

しかし、ダウンロードしたCSVを開いた瞬間、研究者は頭を抱える...

ダウンロードした書誌データ『燕石雑誌』の例

行番号	title_main	creators_name	publisher_name	publisher_location	date	issued
1	燕石雑誌 : 5巻	<u>曲亭</u> 馬琴 1767-1848	河内屋太助 [ほか]	大坂	文化7(1810)	1810
2	燕石雑誌 5巻	<u>滝沢</u> 馬琴	須原屋茂兵衛		1811	1811
3	燕石雑誌	滝沢 <u>馬琴</u> 著	和泉屋平吉	江戸	1811(文化8)	1811-01-01
4	燕石雑誌	滝沢馬琴著	和泉屋平吉	江戸	1811(文化8)	1811-01-01
5	燕石雑誌	滝沢馬琴著	和泉屋平吉	江戸	1811(文化8)	1811-01-01
6	燕石雑誌	滝沢馬琴著	和泉屋平吉	江戸	1811(文化8)	1811-01-01
7	燕石雑誌	滝沢馬琴著	和泉屋平吉	江戸	1811(文化8)	1811-01-01
8	燕石雑誌	滝沢馬琴著	和泉屋平吉	江戸	1811(文化8)	1811-01-01

新字体、旧字体、雅号、元の苗字、役割表示、西暦、和暦、色々な書誌データが混在していて整理が難しい

データは取得よりも分析のための 整理と確認作業が大変！

- …結局、自分の手元で泥臭い手作業(=掃除)を行わなくてはならない。
- 正規表現という文字検索技術で探しながら名称の整理を行う
- 自分でIDをつけて整理する = 名寄せ(名称の統一化)

さらに、検索漏れがないか、さまざまな角度から何回も確認する。

🤔 データに「ない」ことは、存在しなかったことを意味しない。また、データが「ある」からそれが正しい情報であるとも言えない…

研究者が図書館の データベースにほしい機能まとめ

★API機能 (IIIFもAPIの一つと言えます)

👍名寄せに留意されたデータ

さらに、生成AIという「レファレンス・アシスタント」

- 詳細検索画面は高機能だが、入力キーワードがわからないとヒットしない。
(私がなかなか使いこなせていないだけ…🤖)
- 生成AIは図書館員の仕事を奪うものではなく、24時間働けるレファレンス・アシスタントになれるかもしれない。
- 近年は「ハルシネーション」をできるだけ抑制する技術もできている。
- 「江戸時代後期で、旅に関する滑稽本はある？」といった曖昧な問いを、検索クエリに変換するオプション機能があれば、資料との出会いは劇的に増えると考えられる。

【第3部】「オープンサイエンス」という言葉への提言：人文学の壁と「クローズド」の価値

すべてをオープンにはできない

人文学・社会科学で頻繁に収集される研究データ、特にオーラルヒストリー(音声インタビュー)、コミュニティの写真などは、**対象者との信頼関係**で成り立っている。

課題

- FAIR原則(公開・再利用)だけを追求すると、対象者(物・生物なども含む)の安全を脅かすリスクがある。「全公開か、死蔵か」の二択は、文系研究者にとって実効性のないものとなっている。
- そのため、多くの貴重なデータが、**倫理的懸念から**リポジトリに預けられず、個人のPC内で消えていく「ファイル・ドロワー問題」が発生している。



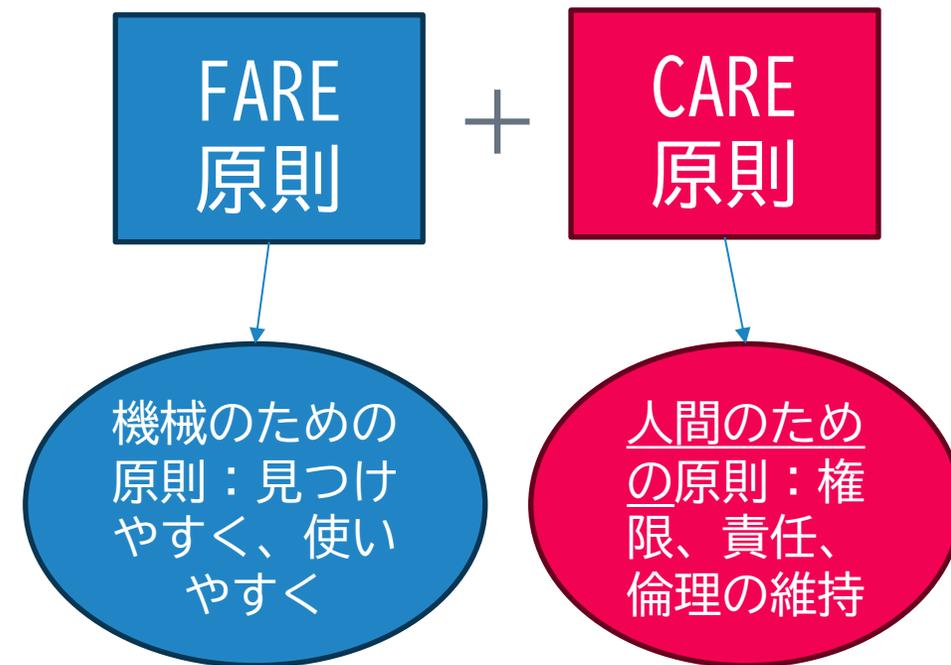
オープンにしにくいデータを守るために考えられた 考え方

★ Shared Authority(共有された権威)[1][2]

- データの管理権限を大学が独占するのではなく、語り手(ナレーター)やコミュニティと分かち合う考え方。

★ CARE原則[3] (Collective Benefit, Authority to Control, Responsibility, Ethics)

- FAIR(データ中心)原則を補完する、人と目的の倫理的な合致を促すための原則。
- Authority to Control(制御する権限): データに関与する当事者が公開範囲に関与する権利を認める。
- クローズドであることは隠蔽ではなく、CARE原則に基づく誠実な管理(スチュワードシップ)である。



FAIR: Findable,
Accessible,
Interoperable,
Reusable

【第4部】次世代の基盤：存在証明と責任共有

人文社会系研究成果公開に向けた解決策①

デジタル研究データの存在証明

デジタルにおける閉架書庫—OPACの実装:

物理図書館	デジタルアーカイブ
閉架書庫 (Closed Stacks) ⊘ 一般利用者は入れない (貴重書・傷みやすい本)	ダークアーカイブ (Dark Archive) ⊘ 生データは非公開 (プライバシー・著作権)
カード目録 / OPAC 書名・場所は公開 「ここにあります」	存在証明 (Metadata Only) メタデータのみ公開 (DOI付与) 「データは実在します」

人文社会系研究成果公開に向けた解決策②

デジタル時代の「特別閲覧」基準

Five Safes: 英国国家統計局(ONS)やUK Data Serviceで採用されている機微データを扱うための5つの安全基準[5][6]。

1.  Safe People: 信頼できる研究者か？(身元の確認)
2.  Safe Projects: 公益性のある目的か？(申請理由)
3.  Safe Settings: 安全な環境(持ち出し不可)か？(館内でのみ閲覧可)
4.  Safe Data: 識別子を除去しているか？(コピーはできない)
5.  Safe Outputs: 論文から個人(事物)が再特定されないか？(統計結果のみ持ち出し可)

人文社会系研究成果公開に向けた解決策③

読ませないが計算させる(著作権法第30条の4)

- 著作権法第30条の4により、「情報解析(計算)」を目的とする場合(=「感情の享受を目的としない利用」)、著作権者の許諾なく利用が原則可能[7]。
- つまり、ストーリーを読むといったことはできないが、統計による分析結果であれば、成果公開できるので、著作権の壁を越えてデータを提供できる道が開ける。

人間 (Human) → 壁にぶつかる
(ストーリーを楽しむ用途はダメ)



機械 (Machine) → トンネルを通過できる (○ 統計結果、例えば、ある単語が何回出現したかなどを公開することはできる)

著作権法第30条の4:運用の課題と留意点

モザイク効果

- 一つ一つのデータは無害(匿名化済み・権利処理済み)でも、複数のデータを組み合わせることで、個人の再特定や、隠すべき情報(希少生物の生息地など)が露見してしまう現象[8]。
- 法律(著作権)はクリアしていても、倫理で事故が起きる可能性がある。機械的な処理だけでなく、人間の判断によるリスク評価が必要。

生成AIは進化が早すぎる

- また、生成AIの発展と普及に法整備が追いつかないことにも留意が必要。

【第5部】 むすび

図書館のみなさまに期待すること

- 「資料の保管・閲覧場所」から、「**知の安全な管理・計算拠点**」へ。
- ひきつづき全ての学生・教職員・一般の方が心理的安全性を保ちながら知を探求できる場所であることを希望します。

おわりに

人文社会科学でよく取り扱われるクローズドデータの管理やFive Safesの運用等は、これまでの業務にはなかった判断を迫られる、新しい挑戦だと思います。

だからこそ、大学のコミュニティにおいて、サービスする側・される側の垣根を越えて、リスクも、手間も、知恵も**分かち合いながら**、一歩ずつ、新しい研究環境を整えていければ幸いです。

参考文献

1. Frisch, M. (1990). *A Shared Authority: Essays on the Craft and Meaning of Oral and Public History*. SUNY Press. (オーラルヒストリーにおける権威共有の基礎理論)
2. 『SHARED AUTHORITY:歴史を描くのは誰か | 国際シンポジウム | イベント | グローバル日本学教育研究拠点』. Accessed February 12, 2026. <https://www.gjs.osaka-u.ac.jp/event/symposium/20240824/>.
3. Carroll, S. R., et al. (2020). "The CARE Principles for Indigenous Data Governance." *Data Science Journal*, 19(1), 43. (FAIR原則を補完する、倫理と責任のための原則)
4. JPCOARスキーマ策定作業部会. (2019). 『JPCOARスキーマガイドライン』. Accessed February 12, 2026. <https://schema.irdb.nii.ac.jp/ja>. (「metadata_only_access」の定義を含む日本のリポジトリ標準)
5. Desai, T., Ritchie, F., & Welpton, R. (2016). *Five Safes: Designing data access for research*. University of the West of England. (英国国家統計局やUK Data Serviceで採用されているデータ公開の標準フレームワーク)
6. UK Data Service. *Secure Lab: What is the Five Safes framework?* Accessed February 12, 2026. <https://ukdataservice.ac.uk/help/secure-lab/what-is-the-five-safes-framework/>
7. e-Gov法令検索. 著作権法(昭和四十五年法律第四十八号)第30条の4. (情報解析のための利用規定). Accessed February 12, 2026. <https://laws.e-gov.go.jp/law/345AC0000000048#Mp-Ch 2-Se 3-Ss 5>
8. Ohm, Paul. (2010). "Broken Promises of Privacy: Responding to the Surprising Failure of Anonymization." *UCLA Law Review*, August 18. Accessed February 12, 2026. <https://www.uclalawreview.org/broken-promises-of-privacy-responding-to-the-surprising-failure-of-anonymization-2/>.