

# デジタル人文学への招待ーAI、 共同研究、デジタル変革



北本 朝展 (Asanobu KITAMOTO)

ROIS-DS人文学オープンデータ共同利用センター  
(CODH)

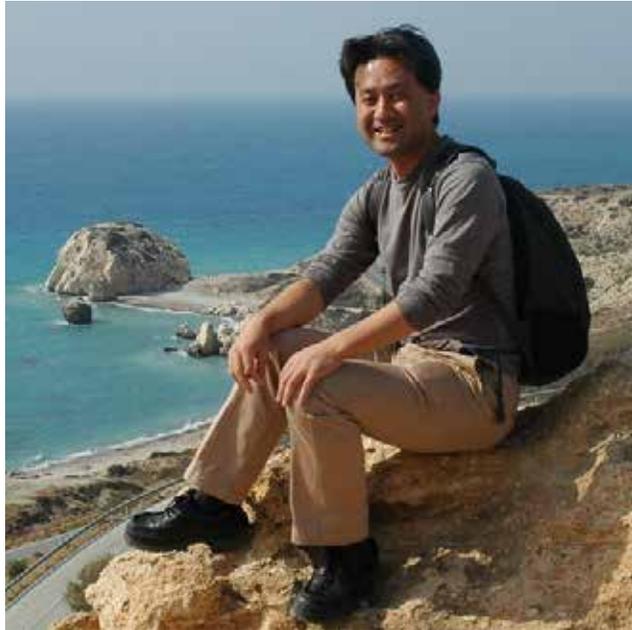
国立情報学研究所

<http://codh.rois.ac.jp/>

<https://researchmap.jp/kitamoto/>

# 自己紹介

<https://researchmap.jp/kitamoto/>



@kitamotoasanobu

- 北本朝展（きたもと あさのぶ）
- 国立情報学研究所 教授、ROIS-DS人文学オープンデータ共同利用センター センター長
- 専門は、情報学、デジタル・ヒューマニティーズ、データ駆動型サイエンス（地球科学・防災等）など。オープンサイエンスの展開に向けた、超学際的な共同研究の展開にも取り組む。

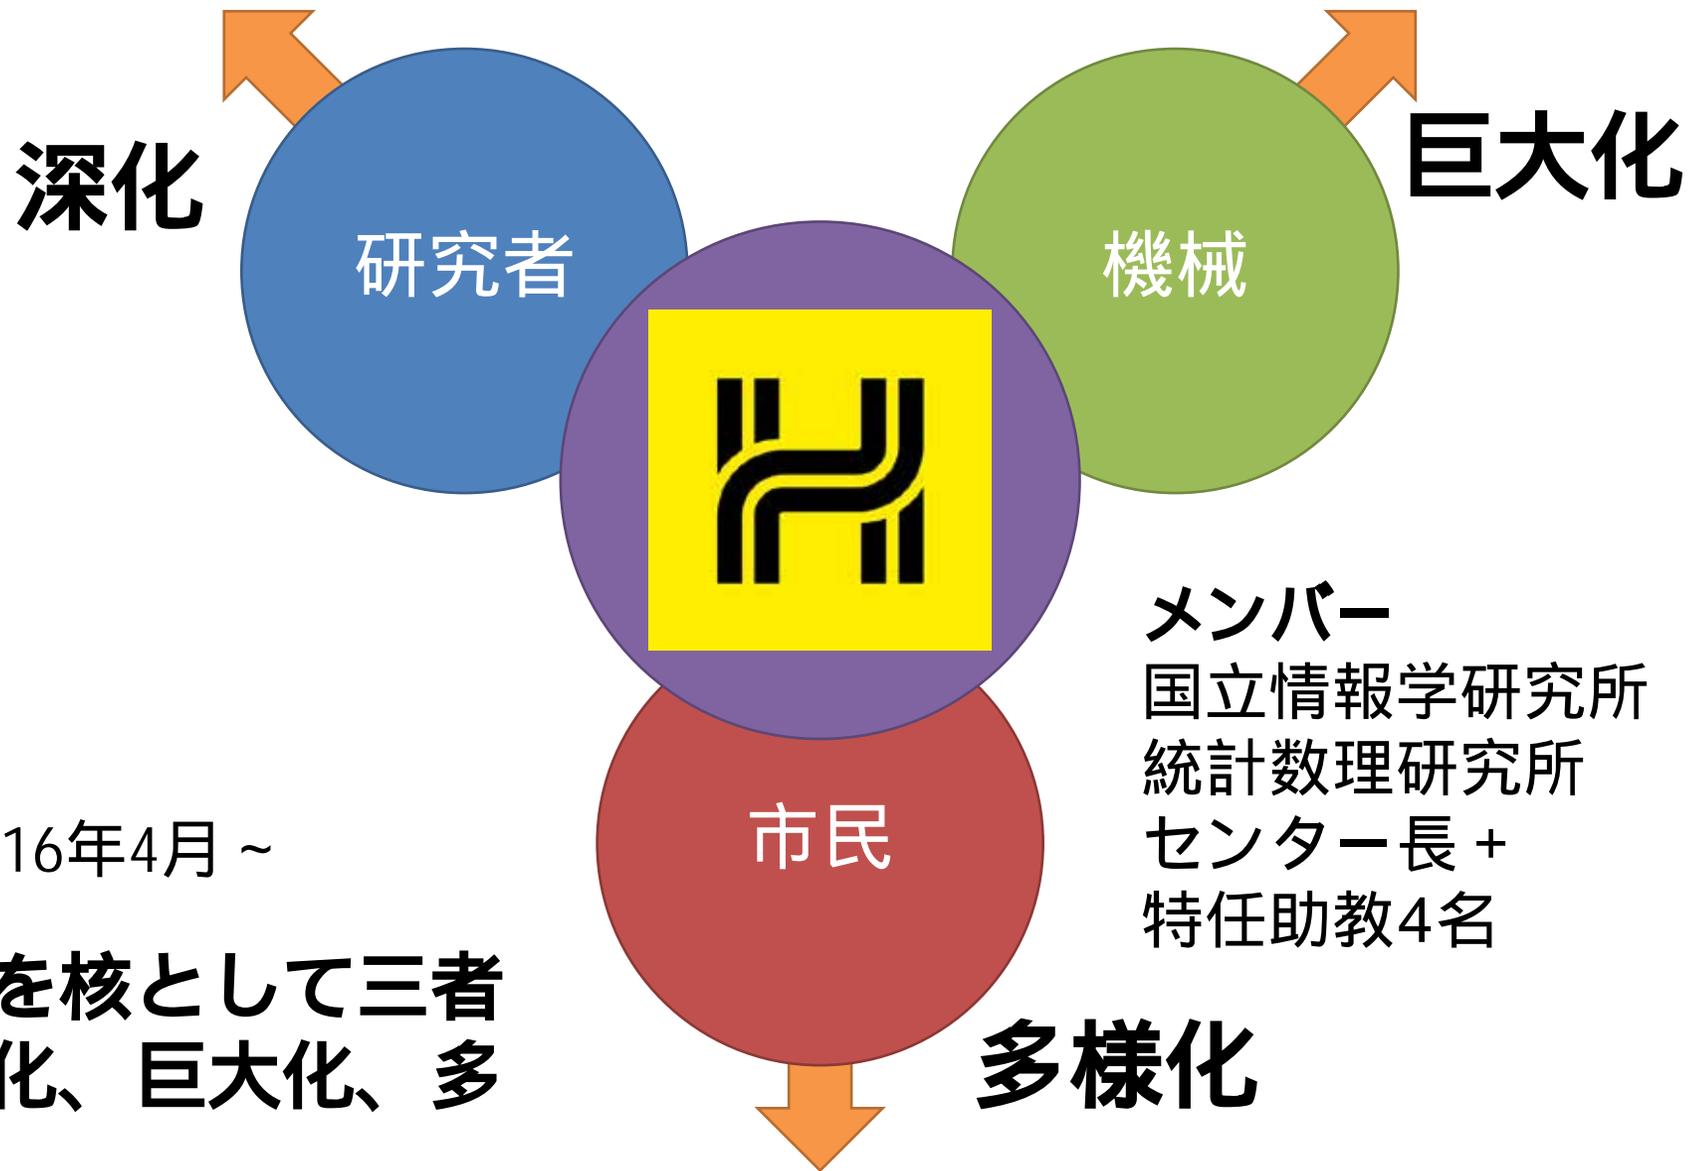
# ROIS-DS人文学 オープンデータ 共同利用セン ター（CODH）

<http://codh.rois.ac.jp/>



2016年4月～

「オープン」の概念を核として三者  
を接続し、知識の深化、巨大化、多  
様化を目指す



# デジタル人文学とは？

1. **デジタル技術を人文学研究に導入することで、人文学の新しい研究方法を考案し、新しい知識を得ること。**
2. **デジタル技術の一つが「人工知能（AI）」。**人間と機械の分業（協力）により、研究方法の変革が起こる。
3. **コロナ禍が明らかにしたこと＝リモートでアクセスし、議論し、共有できることの価値も大きい。**
4. **共同研究（チーム）が重要性を増す＝「ワンオペ」では研究資源が足りないため、協働の文化が鍵を握る。**



眼の誕生—カンブリア紀大進化の謎を解く, アンドリュー・パーカー, 草思社, 2006

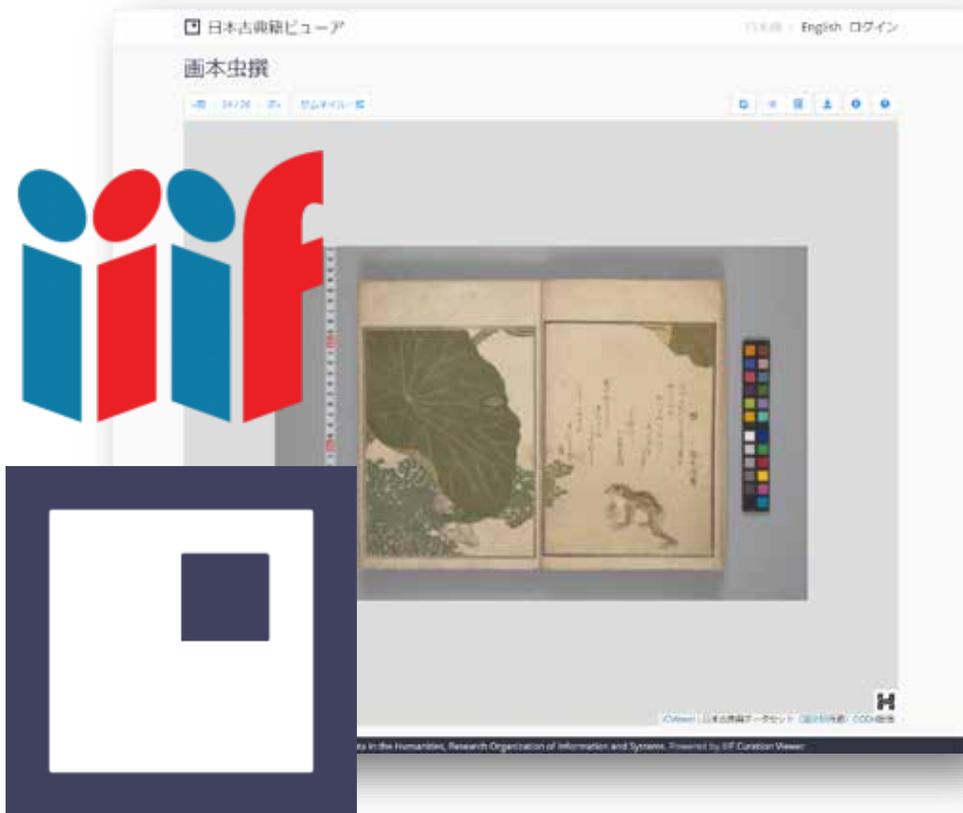
# AIによる新しい研究方法

- AIという新しいツールによって、「見えるもの」が変わる。
- 遠読（distant reading）：大量のテキストを機械が読み込み、データからパターンを見出す。
- Google BooksとN-gram viewer：数百年にわたる語の使用頻度の推移をグラフ化し、社会の変化を探る。

# オープンサイエンス

IIF Curation Platform

<http://codh.rois.ac.jp/icp/>



1. **オープンデータ**を公開することで、許可なく、誰でも、データを活用した研究ができる。
2. **オープンソースソフトウェア**によって、無料で、改造可能な研究の基盤が使えるようになる。
3. **超学際的な研究者の協働、市民参加（支援）**などによって、従来型共同研究の枠を超えて、技術や知識の多様性を高める。

# どのように共同研究するか？

人文学者と情報学者では、関心のありかが異なる！異文化への理解と、ゴールを共有できる相手が必要。

1. **人文学者のリサーチクエスション**をきっかけとして、情報学者がデータ化、システム化の手法を練っていく。
2. **情報学者の技術的提案**をきっかけに、人文学者が自分の研究への活用を進め、システムの課題を出していく。
3. **人文学者と情報学者がアイデアを議論**しながら、新しい研究課題と技術的な解決策を探していく。

# 篆書字体データセットの事例

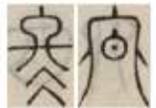
<http://codh.rois.ac.jp/tensho/>



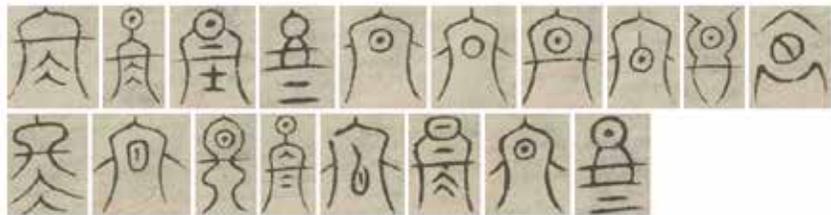
撫古遺文 [TE00002] (5)



聯珠篆文 [TE00003] (2)



万象千字文 [TE00004] (18)



人文学者



情報系に近い人文学者



人文系に近い情報学者



情報学者

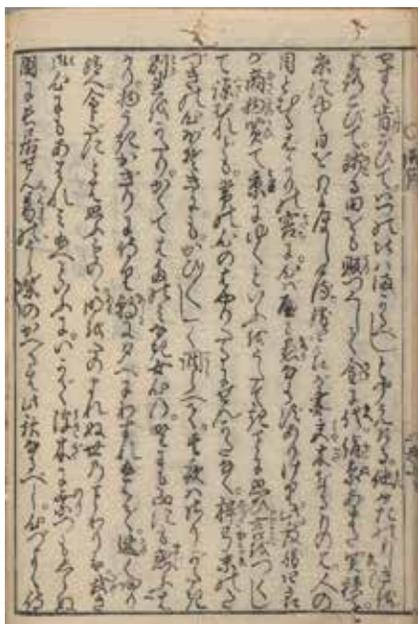
人文学者（国文研青田 寿美先生）のプロジェクトに、情報学者の立場から、データセット構築に協力。

教訓：分野間の橋渡し人材がいないと、協働はスムーズに進まない。

# くずし字データセットの利活用例

<http://codh.rois.ac.jp/char-shape/>

日本古典籍  
データセット  
(国文研蔵)

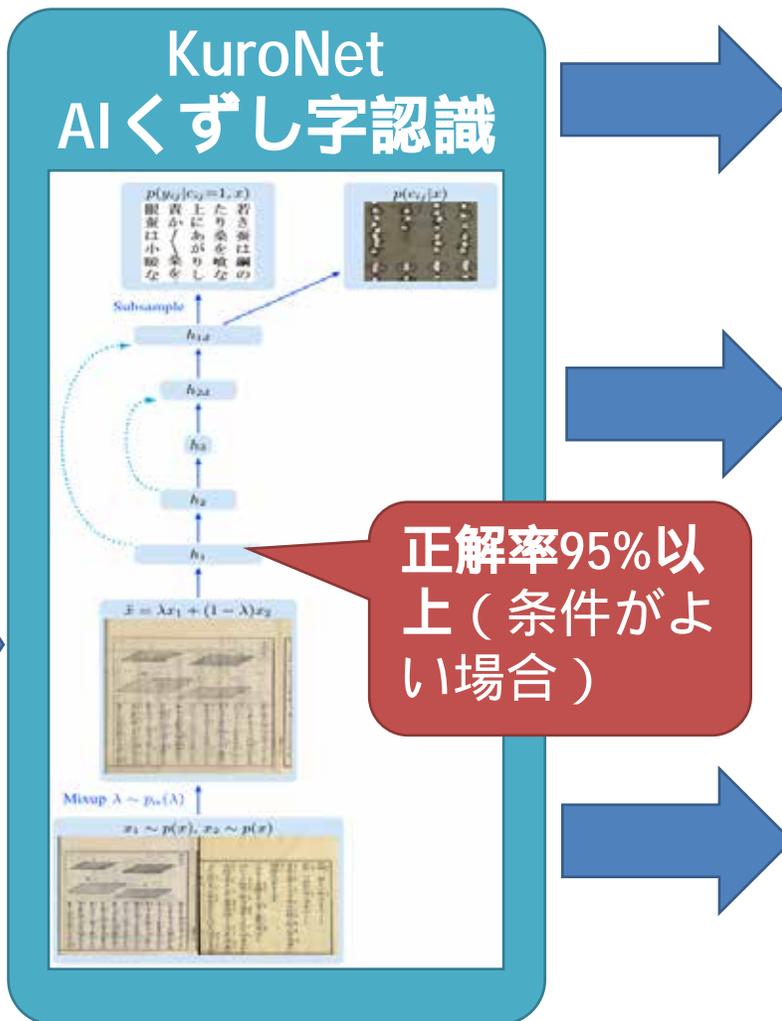


くずし字データ  
セット (国文研・  
CODH作成)



file	char	x	y
200003803_00024_2.jpg	U+3067	416	114
200003804_00024_2.jpg	U+3055	232	115
200003805_00024_2.jpg	U+304A	327	115
200003806_00024_2.jpg	U+3068	145	116
200003807_00024_2.jpg	U+3046	369	116
200003808_00024_2.jpg	U+305F	457	116
200003809_00024_2.jpg	U+5FA1	104	117
200003810_00024_2.jpg	U+3072	191	118
200003811_00024_2.jpg	U+540D	279	120
200003812_00024_2.jpg	U+3061	501	120

CODH カラーヌワット・タリンほか



くずし字認識サービス



くずし字認識コンペ



AIくずし字認識アプリ  
「みを」

# くずし字データセットの事例

<http://codh.rois.ac.jp/char-shape/>

1. **国文研のNIJL-NWプロジェクト**では、古典籍のデジタル化に加え、テキストの全文検索も構想していた。
2. くずし字データセットを構築し、AIくずし字認識（機械学習）を開発する計画も始まっていた。
3. **当初想定 of データ形式では機械学習の可能性が狭まること**に気づき、情報学者として仕様変更を主張した。
4. この仕様変更は、その後のKuroNetの開発やKaggleコンペの開催において、決定的に重要な役割を果たした。

**教訓：情報学者がデータの仕様策定段階から入るべき。**

# 顔コレデータセットの利活用例

<http://codh.rois.ac.jp/face/>

日本古典籍データセット（国文研蔵ほか）



IIIF Curation Viewer / IIIF Curation Platform  
（CODH開発）



顔貌コレクション・データセット（CODH作成）



美術史研究



AI自動顔認識



機械の創造性  
（GAN）

CODH 鈴木 親彦、東大 高岸 輝、Google Yingtao Tian、EPFL Alexis Mermetほか

# 顔コレデータセットの事例

<http://codh.rois.ac.jp/face/>

1. CODHでは、IIIF画像を切り取り集める機能を備えた、**オープンソースのIIIF Curation Platformを開発**している。
2. **人文学者（美術史）**が、顔を切り取って集めたら面白いのではないかと考えた。
3. 自らによる作業に加え、**大学院生への謝金も活用し**、数千枚の画像コレクションを構築した。
4. 顔データをオープン化することで、**機械学習研究者が顔認識モデルを開発**し、半自動切り抜きに発展した。

教訓：人文学者が構築した高品質なデータセットは、機械学習研究者が新たな研究を始めるきっかけになる。


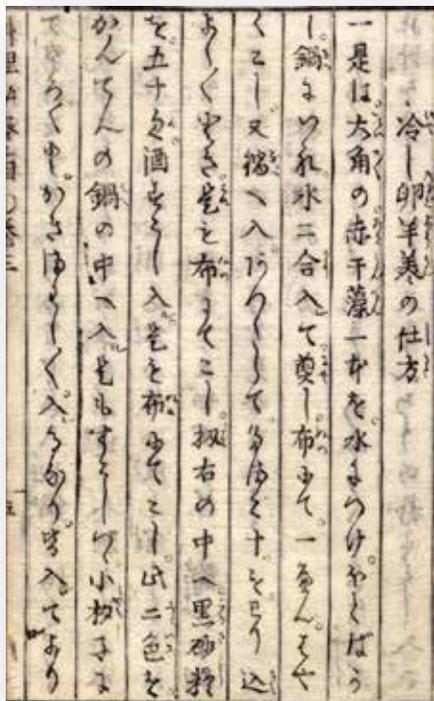
# 江戸料理レシピの利活用例

<http://codh.rois.ac.jp/edo-cooking/>

日本古典籍  
データセット  
(国文研蔵)

データクリエイター、  
料理研究家との協働  
(CODH主導)

江戸料理レシピ・データ  
セット (CODH作成)



料理レシピサイト



デパートイベント



業界新聞特集記事

# 江戸料理レシピの事例

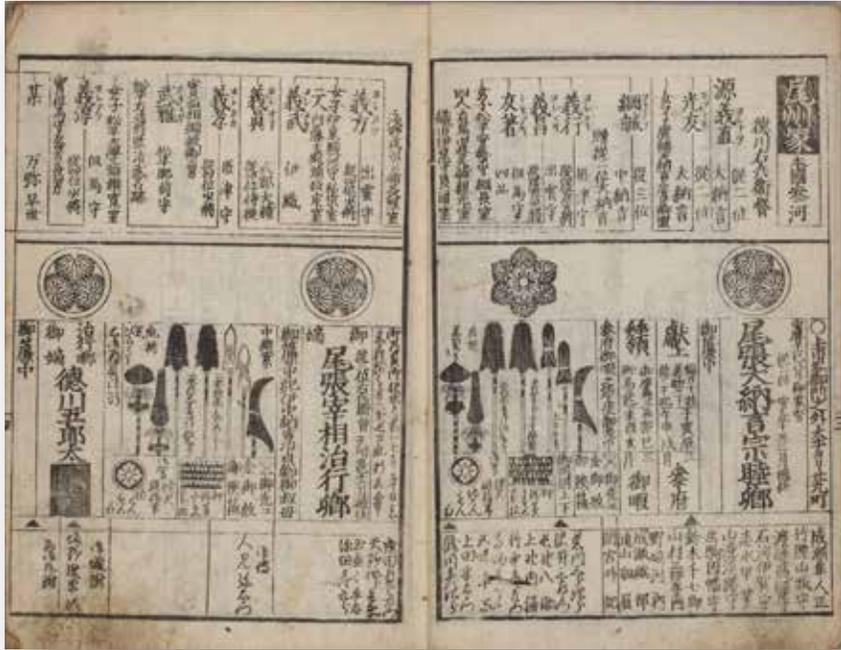
<http://codh.rois.ac.jp/edo-cooking/>

1. 国文研が主催するアイデアソンに、情報学者である北本が参加して、江戸の料理本に触れる。
2. レシピに写真を加え、料理レシピサイトに投稿すれば、現代の生活と接続できるのではないかと思いついた。
3. クックパッドに連絡して共同研究体制を構築。翻刻とレシピ化が可能なデータクリエイターに作業依頼。
4. プロの料理研究家が参画し、調理可能なレシピ化と写真撮影を進め、現代にも通用する水準のレシピを完成。

教訓：アイデアの現実化には、多様な専門性を備えたチームの協働が必要である。

# 「武鑑」の網羅的な解析

<http://codh.rois.ac.jp/bukan/>



寛政武鑑 (1789)、日本古典籍データ  
セット (国文研蔵、CODH公開)

<http://codh.rois.ac.jp/pmjt/book/200018823/>

1. 江戸の大名や幕臣に関する「データブック」。紋などのパターンも含み、豊富な構造化データを記録。
2. 実用：役職移動情報、江戸観光みやげ、大名行列観覧ガイド等。
3. 江戸時代の約200年にわたって出版され続けたベストセラー。
4. 貴重な大規模データを、デジタル人文学研究に使える形式にしたい。

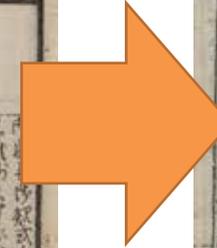
参考：藤實 久美子、江戸の武家名鑑 武鑑と出版競争、吉川弘文館、2008

# 差分翻刻のアイデア

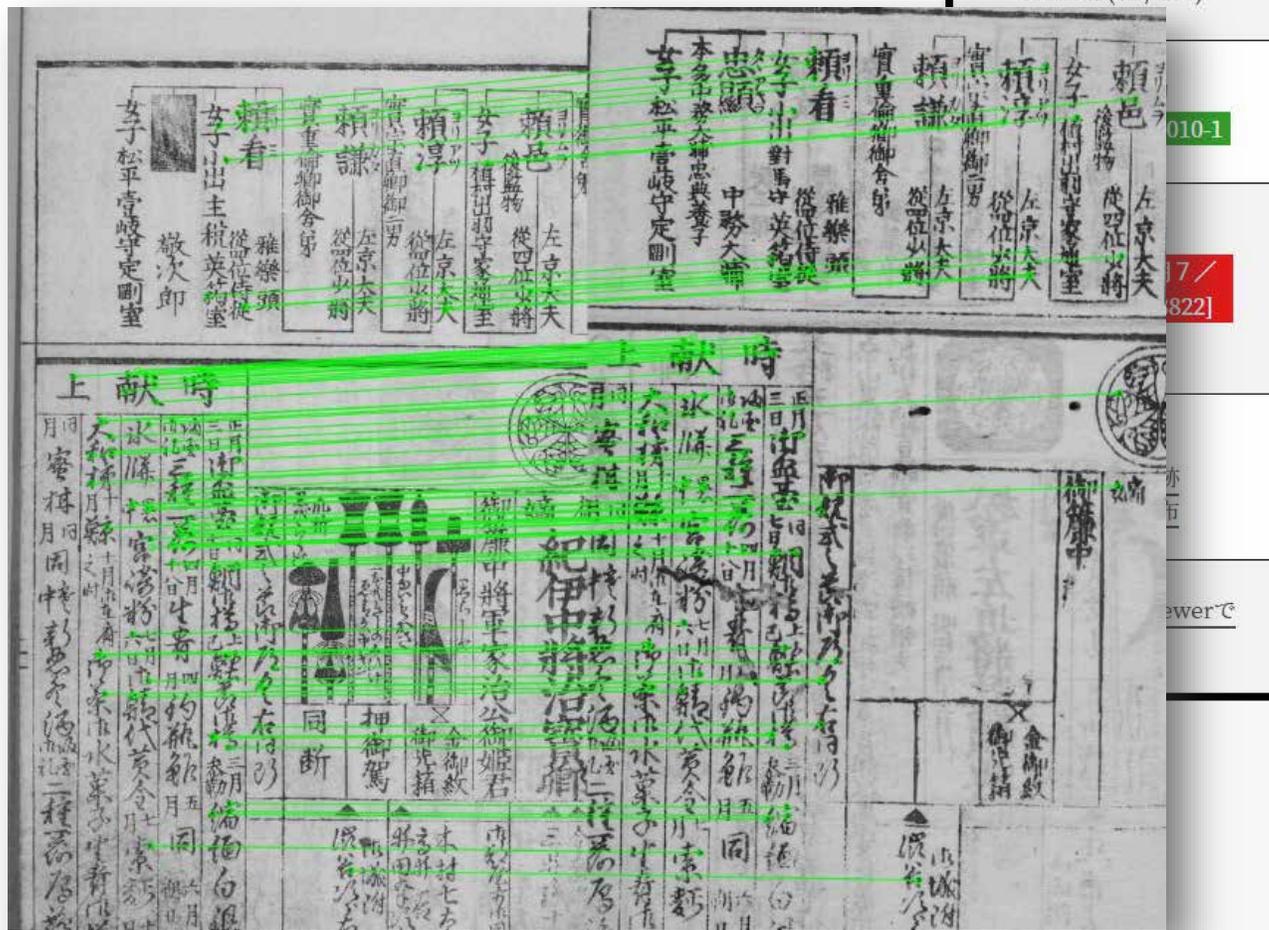
問い：200年にわたる史料をどう翻刻するか？



解決：前後のバージョンで変化した部分のみを翻刻し時系列データを構築する。



# ページ照合



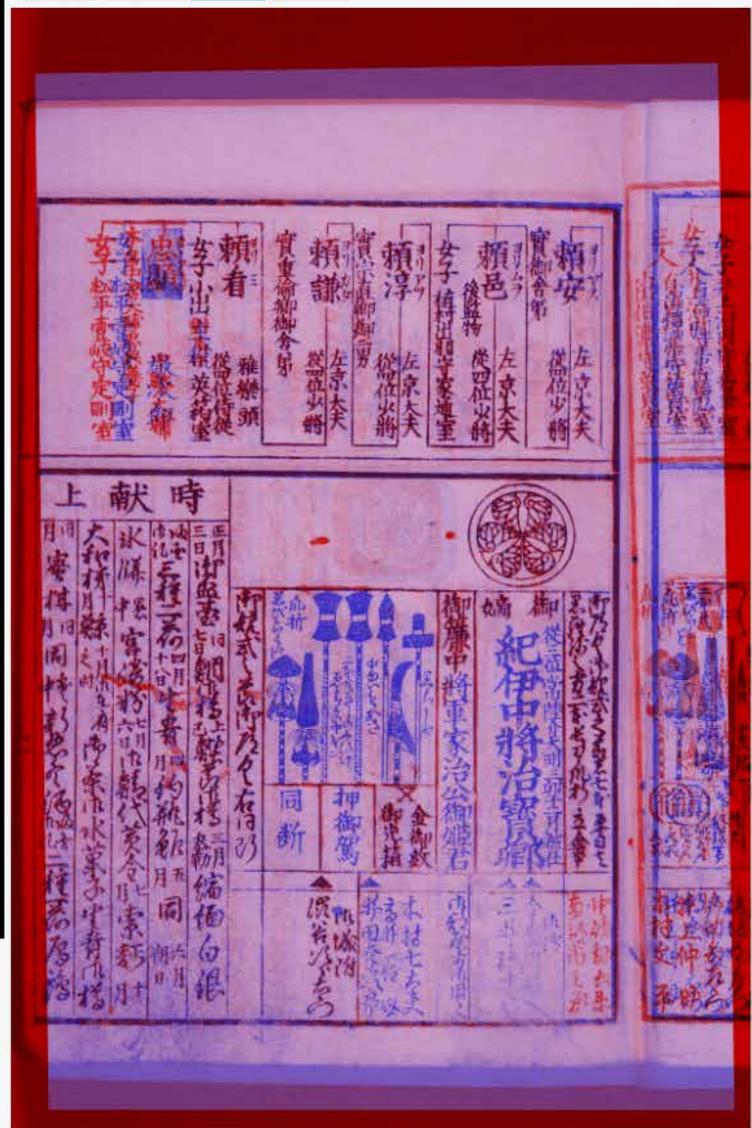
寛政武鑑 (寛政1/  
1789) [200018823]

特徴点マッチング  
00010-2 (33 / 250)

010-1

17 /  
822]

viewerで



寛政武鑑 (寛政3/  
1791) [200018825]

特徴点マッチング  
00011-2 (33 / 582)

ページ移動

00012-1 ■ 00011-1

ブック移動

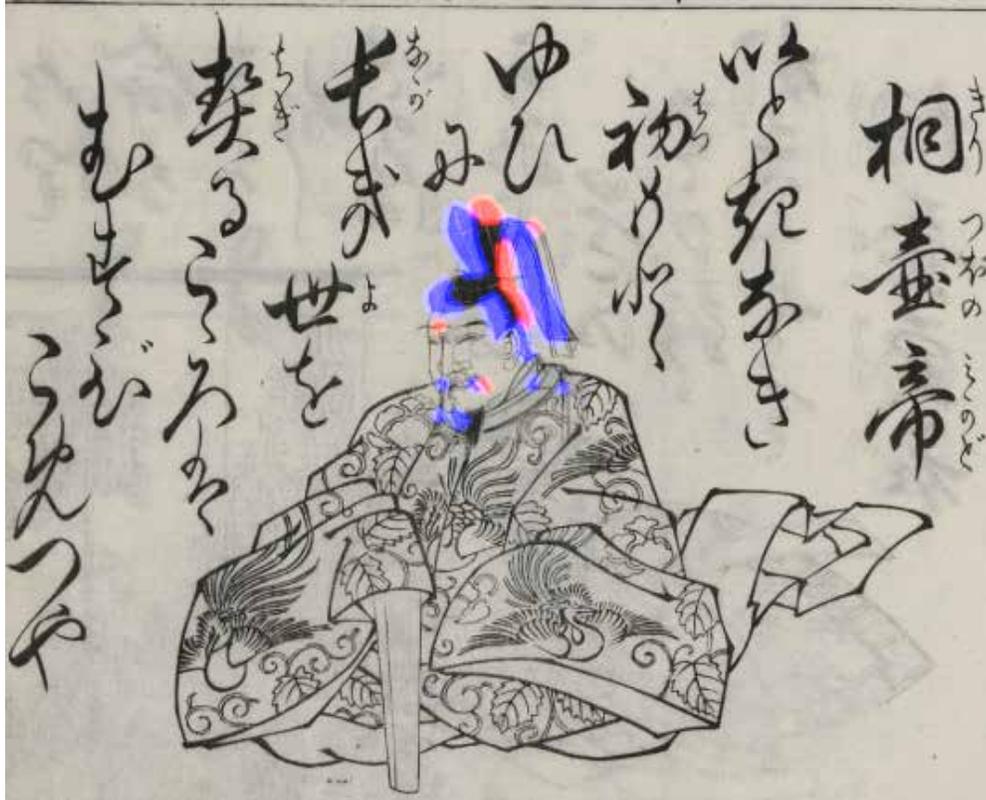
寛政武鑑 (寛政7/  
1795) [200018828]

板木

同一板木追跡  
同一板木分布

IIIF Curation Viewerで  
閲覧

# 差読（Differential Reading）のための画像 照合サービス <http://codh.rois.ac.jp/differential-reading/>



源氏百人一首（パタパタ顔比較）、東京大学総合図書館

1. **vdiff.js**を活用し、**任意の画像**を指定し、照合結果を表示・共有できるサービスを公開。
2. **ウェブ版** = URLを指定
3. **ファイル版** = フォルダを指定
4. **外部サービス**と連携可能。

# 武鑑全集の事例

<http://codh.rois.ac.jp/bukan/>

1. 情報学者である北本が武鑑を見たとき、異なる版の比較問題にコンピュータビジョン技術が使えることに気づく。
2. 技術は15年以上前から存在したが、それが版本の版間差分の強調に使えるという発想が乏しかった。
3. 武鑑研究の第一人者である藤實久美子教授に相談し共同研究開始。当時は岡山で勤務していたが、その後国文研に異動。
4. 任意の版本を比較できるプラットフォームへと発展できれば、書誌学的な研究において画期的な効率向上が期待できる。

教訓：技術がきっかけの例。問題そのものは昔からあったが、技術の動向を知らないと、適切な解決策は思いつけない。

# 歴史ビッグデータの統合解析

<http://codh.rois.ac.jp/historical-big-data/>

過去のビッグデータを統合解析するための基盤技術の研究



自然科学的データ

人文社会的データ

気候

地震

噴火

疫病

経済

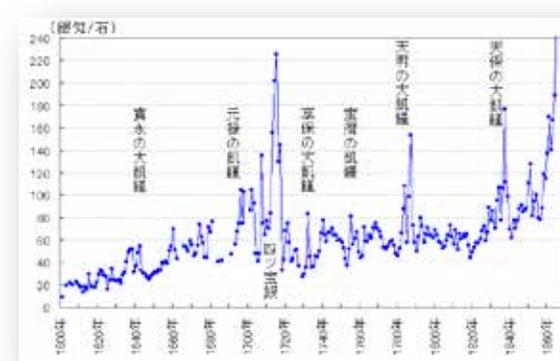
人口

政治

文化

データ  
構造化  
ワーク  
フロー

歴史ビッグ  
データ研究基  
盤 (機械可読  
データ)



# 江戸ビッグデータの統合

<http://codh.rois.ac.jp/edomi/>

画像：江戸切絵図（国立国会図書館）

地名：CODHが、データクリエイターと共に、IIIF画像への注釈としてデータ整備



CODH 鈴木 親彦ほか



現代地図との重ね合わせ

地名識別子の整備・共有 (CODH)



GeoLOD

<https://geolod.ex.nii.ac.jp/>



商業ビッグデータ



観光ビッグデータ

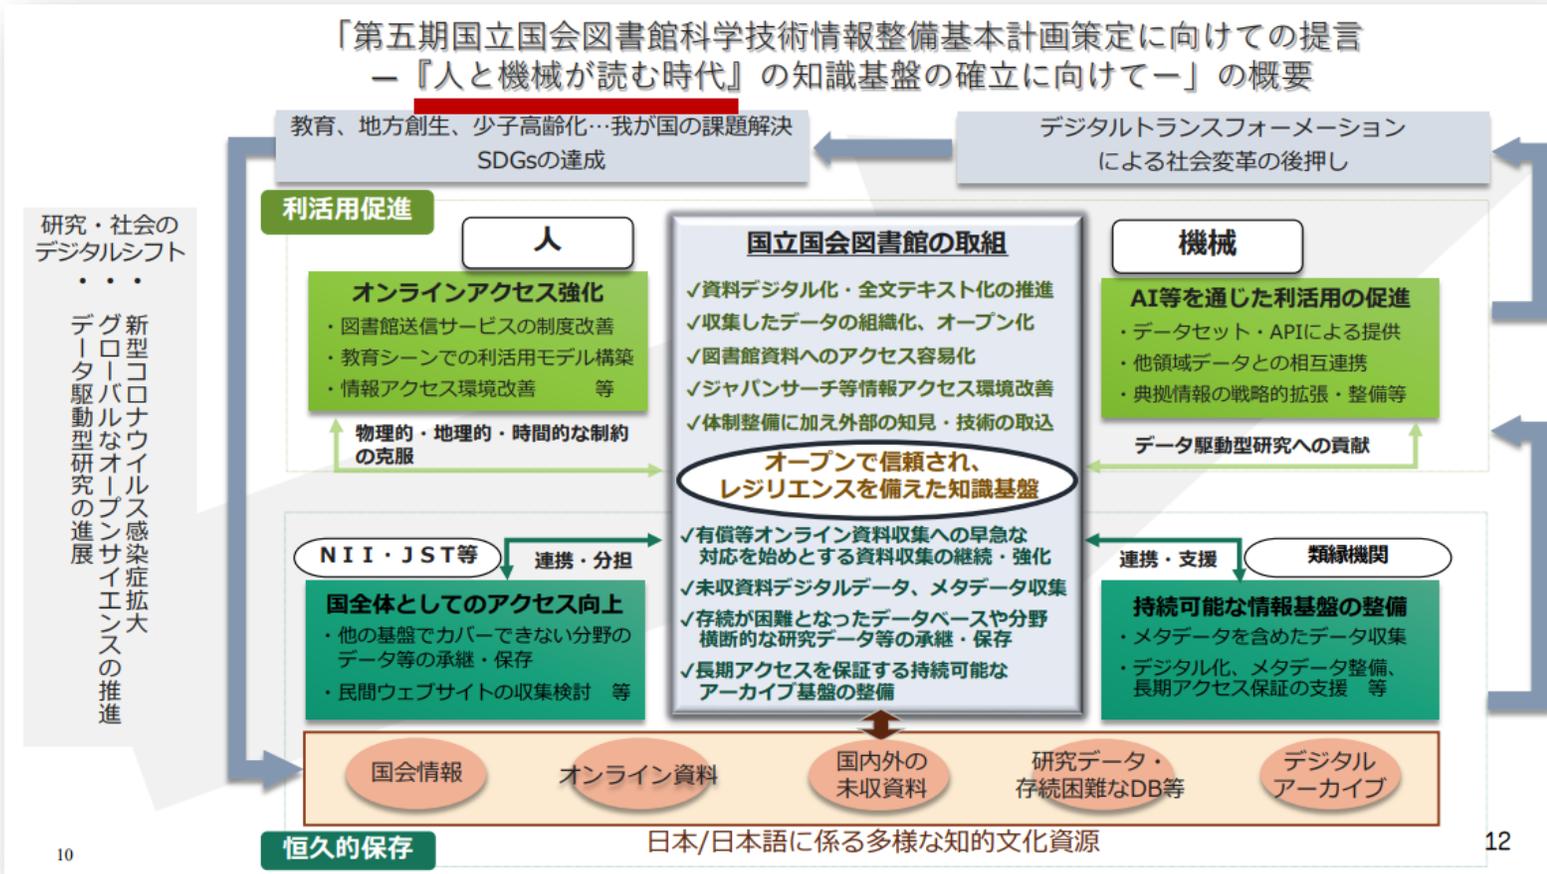
# 江戸ビッグデータの事例

<http://codh.rois.ac.jp/edomi/>

1. 国立国会図書館などが公開するIIIF画像に対して、CODHがアノテーション（注釈）を加え、付加価値を生みだした。
2. IIIFの相互運用性を活用することで、機関横断的にアーカイブを統合し、基盤データに新たな付加価値を与えられる。
3. GeoLODという地名識別子を活用することで、異なる分野のデータセットを統合し、「総合知」につなげていく。
4. 地理情報や業種分類、観光地などを現代と接続することで、日本文化の資産として活用していく道が開ける。

教訓：相互運用性・識別子などを、機関や分野をまたいで共通化することで、データセットの付加価値はさらに高まる。

# 図書館の役割



1. 図書館の読者として「機械」を想定しているか？機械が訪問しやすい図書館とは何か？
2. 機械の助けによって、図書館の価値を上げられるか？全文検索など、新しいサービスを作れるか？

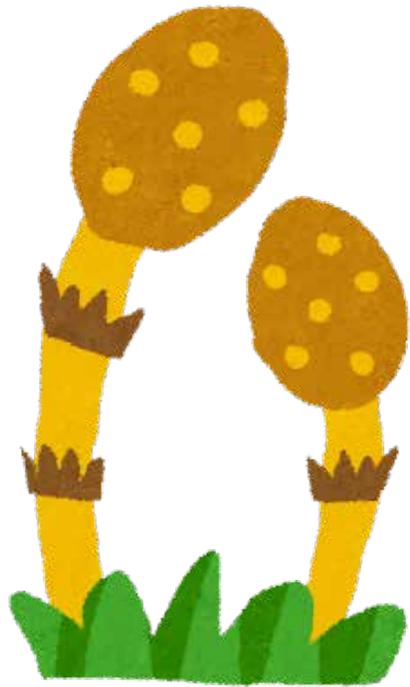
「人と機械が読む時代」の知識基盤の確立に向けて

<https://dl.ndl.go.jp/info:ndljp/pid/11631622>

# 機械が訪問しやすい図書館とは？

1. **共通の方式でアクセスできる。**
  - IIF（International Image Interoperability Framework）など、どこの組織のデータにも共通の方式でアクセスできる。
2. **使いやすいライセンスが設定されている。**
  - クリエイティブ・コモンズ（Creative Commons）など、オープンな利用に対応可能な利用許諾方法を提供する。
3. **識別子などの仕組みで資料に安定してアクセスできる。**
  - DOI（Digital Object Identifier）など、長期間にわたって、同一の方法で、資料を識別しアクセスできる保証がある。

# 機械で価値を増す図書館とは？



可愛いつくしのイラスト  
いらすとや

1. 機械を用いて、「人が読む」ための新しいサービスを実現する。
2. 人間の技術や知識によって、機械を賢くできれば、好循環が回り出す。

例：日本古典籍（古文書？）に、AI  
くずし字認識を適用し、全文検索エ  
ンジン「つくし」を実現すれば、古  
典籍の研究方法は大きく変わる！

# 人文学研究とデジタル変革（DX）

AIなどのデジタル技術の活用、従来の枠を超えた共同研究などにより、人文学の研究手法を変革し、これまでにない新しい知識を得る。

1. 機械の役割は「下読み」や「検索」など人間（専門家）の支援。「知識」や「発見」は人間の役割であり、**研究者が不要になることはあり得ない。**
2. **機械の支援で新しいものが見えてきた研究者は、そうでない研究者に比べて優位になる可能性がある。**