

ジャパンサーチ利活用フォーマット

1. 基本データモデルの考え方
2. ソース情報分離モデル
3. 共通情報の主要項目
4. 扱いやすさと適切さのバランス
5. 寄与(者)関係の共通情報表示例
6. 時間関係情報
7. 時間関係の共通情報表示例
8. 場所関係情報
9. 場所関係の共通情報表示例
10. 提供=アクセスのための情報
11. 提供/ソース関連の共通情報表示例
12. ライセンス情報の明示
13. 共通情報整備の課題

1 基本データモデルの考え方

■ ソース情報の分離と利用者のタスクに基づく共通情報

- 提供元からのソースデータは来歴情報明記の上でそのまま保持
- 利用者の4つのタスクの観点で共通情報を生成
 - ▶ **Find** : 発見=タイトル、キーワードなどによる検索 (標目、アクセスポイント)
 - ▶ **Identify** : 識別=示されている対象が何なのか、求めている (既知の) コンテンツかどうか判断できる情報
 - ▶ **Select** : 選択= (検索結果などの) 選択肢のうち、対象が求めている (未知の) コンテンツかどうかを判断できる情報。識別より広い意味での記述
 - ▶ **Obtain** : 取得=示されている (選択した) 対象を取得する手段 (の情報) の提供

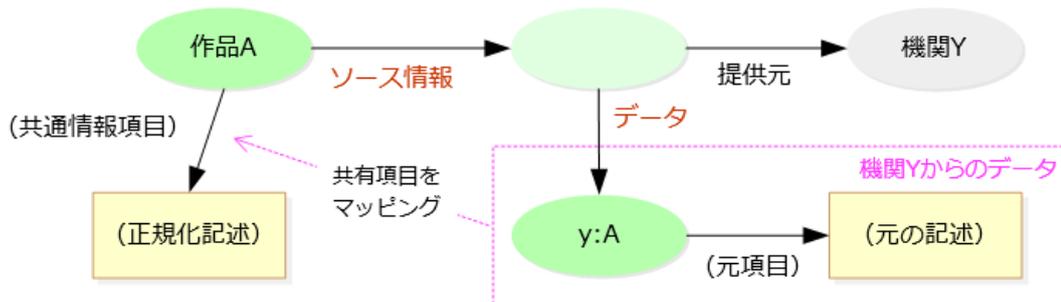
■ 共通情報とタスク

- いつ、どこで、だれが、何を (→特に発見タスク) を基本にシンプルな項目設定
- 単純プロパティと構造的プロパティの併置 (識別、選択タスク)
- 提供=アクセス情報の充実 (取得タスク)
- アプリケーションによる活用も踏まえた情報形態 (Linked Data)

2 ソース情報分離モデル

■ 共通情報とソースデータ/情報

- 利用者タスクに基づき、共通利用や付加価値を持つ再利用のための項目をマッピング
- 共通情報項目の1つとして「ソース情報」を持ち、ソースデータをそのまま保持
 - ▶ ソースデータはJSONに変換して保持し、単純検索、全文検索などでも利用



■ Europeana、DPLAとの関係

- Europeana、DPLAともに収集データとそれを整理した共通データを分離して扱っている
 - ▶ Europeanaは提供元に一定の標準モデル準拠を求める。DPLAは複数形式を許容
- Europeanaは値の正規化、Linke Data化を重視。ジャパンサーチはより多様な活用が可能なモデルを工夫

3 共通情報の主要項目

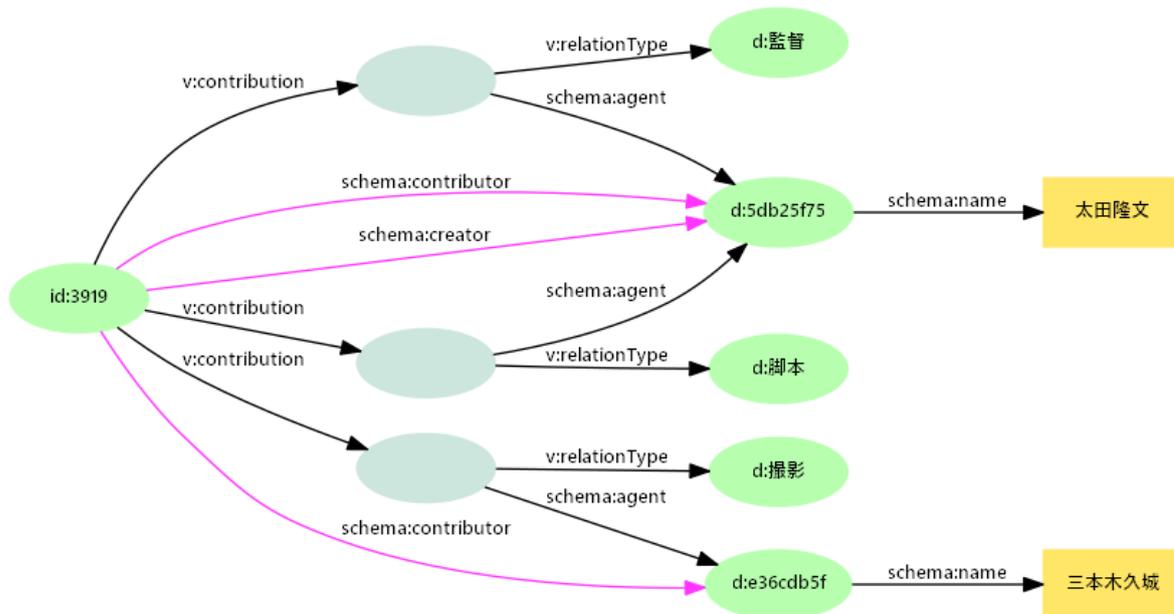
■ 共通情報の基本項目

基本項目	内容
タイプ	コンテンツの基本区分（書籍、文化財など大きく情報を区分する枠）
名称	タイトル、別名、読みなど検索対象とする名前
寄与(者)関係	コンテンツに寄与した人／組織（作者、発行者、出演者など）
場所関係	場所に関する情報（発行地、制作地など）
時間関係	時間に関する情報（制作年、対象時期など）
主題／区分	主題・分類／各分野のキーワード的共通認識のある区分（国宝、ドキュメンタリーなど）
識別子,言語	コンテンツを特定するための識別子（ISBNなど）、コンテンツの記述言語
サムネイル画像	コンテンツの特徴を確認するための画像（提供元とは別にサムネイルを保持）
記述	コンテンツの物理的特徴・素材等の記述、個別項目に収録できない情報
上位コンテンツ	当該コンテンツがその一部である上位コンテンツ（公文書などの資料階層）
提供情報	コンテンツの提供・アクセス、ライセンスに関する情報（構造化して記述）
ソース情報	ソースデータ（ジャパンサーチ(仮称)が連携フォーマットで受け取ったデータ）とその提供者に関する情報（構造化して記述）

4 扱いやすさと適切さのバランス

■ 単純プロパティと構造化プロパティの併用

- 監督、脚本=太田隆文；撮影=三本木久城というメタデータがある時
- **単純プロパティ**：作者は共通のプロパティ creator で調べたい。関与した人は一括して contributor で調べたい（発見）→原則としてSchema.orgを使用
- **構造化プロパティ**：監督、照明といった元データの項目情報も生かしたい（識別、選択）→必要に応じて独自語彙



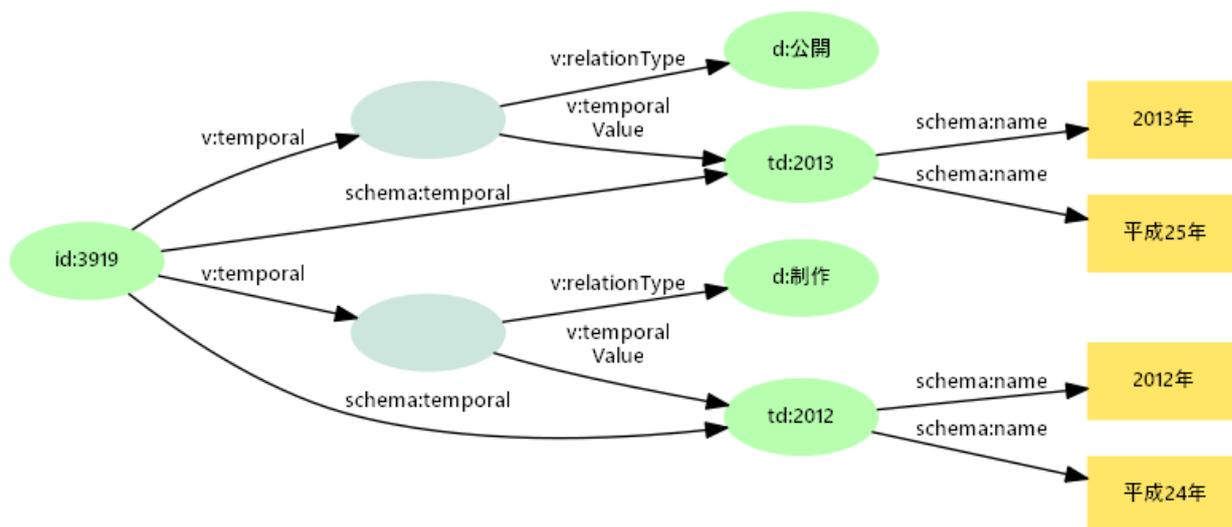
5 寄与(者)関係の共通情報表示例

v:contribution	schema:roleName	「撮影」	schema:agent	ndlent:00444960 (☞ James Joyce)
	schema:agent	d:今村互 ☞	v:relationType	d:制作 ☞
	v:relationType	d:staffs ☞		
v:contribution	schema:roleName	「編集」	schema:agent	ndlent:00040168 (☞ 丸谷オー)
	schema:agent	d:太田隆文 ☞	v:relationType	d:翻訳 ☞
	v:relationType	d:staffs ☞		
v:contribution	schema:roleName	「平田俊夫」	schema:agent	ndlent:00049772 (☞ 永川玲二)
	schema:agent	d:並樹史朗 ☞	v:relationType	d:翻訳 ☞
	v:relationType	d:casts ☞	schema:agent	ndlent:00078566 (☞ 高松雄一)
v:contribution			v:relationType	d:翻訳 ☞
			schema:agent	d:日本障害者リハビリテーション協会 ☞
			v:relationType	d:出版 ☞

6 時間関係情報

■ 「いつ」に関する情報を集約する

- 制作、収集、内容（対象時代）を区別せずに時間関係として扱う（発見）
- 構造化プロパティで関係の違いを示す（識別、選択）
 - ▶ 値は年を単位に正規化し、元記述が月日まで含むなどの場合は構造化情報に保持する



- 時間を文字列ではなくURIで表し、西暦と和暦、時代区分の対応などを「時間オントロジー」としてまとめる
 - ▶ 時間範囲も `td:1868_1913` のようなURIを介して開始年、終了年を構造化することで、単一年の値と同様に処理できる（DPLAでも時間範囲は構造化）

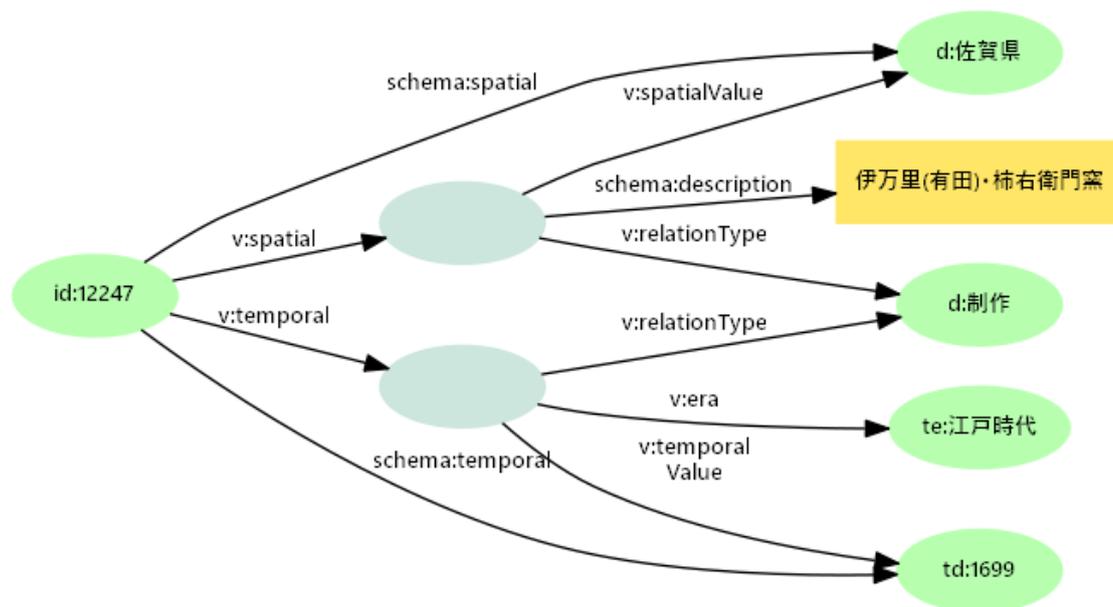
7 時間関係の共通情報表示例

v:temporal (2) ☒	v:relationType	d:公開 ☒
	v:temporalValue	td:2013 ☒ (⇨ 平成25年)
v:temporal	v:relationType	d:制作 ☒
	v:temporalValue	td:2012 ☒ (⇨ 平成24年)
v:temporal	v:era	
	v:temporalValue	td:1903 ☒ (⇨ 明治36年)
te:明治時代 ☒		
schema:name (2) ☒		"1868~1913年"
schema:name		"明治時代"
owl:sameAs		td:1868_1913 ☒
v:temporal		
schema:description		放送開始日:2013/12/29 ☒
v:relationType		d:放送 ☒
v:temporalValue		td:2013 ☒ (⇨ 平成25年)

8 場所関係情報

■ 「どこで」に関する情報を集約する

- 時間軸と同じく、空間（場所）関係を一括して扱う（発見）
- 関係の違いは構造化プロパティで示す（識別）
- 同じ関係（たとえば「制作」）により、同じ関係を持つ時間、場所、関与者などが結びつく
- 場所を都道府県単位（国単位）で正規化→地域活性化のためのデータ利用



9 場所関係の共通情報表示例

v:spatial	v:relationType	d:制作	
	v:spatialValue	d:伊万里(有田)・柿右衛門窯	
v:spatial	v:relationType	d:出土	
	v:spatialValue	d:佐味田宝塚古墳 (奈良県北葛城郡河合町) 出土	
v:spatial	schema: description (2)	採集場所：都道府県 (日本語) :静岡県	d:関連地名
	schema: description	採集場所：詳細 (日本語) :梨本 南伊豆	d:加賀
	v:relationType	d:採集	d:関連地名
	v:spatialValue	d:日本	d:越中
v:spatial	v:relationType	d:関連地名	
	v:spatialValue	d:能登	

10 提供 = アクセスのための情報

■ コンテンツにアクセスするための情報

- 提供者（保管者）の情報
- 提供者のコンテンツ概要ページなどへのリンク
 - ▶ アクセス情報とソース情報の提供者は、一致する場合もあれば、異なる場合（つなぎ役がソース情報提供者）もある
- 提供者においてコンテンツを確認するための識別子（請求記号など）

■ デジタルコンテンツにアクセスするための情報

- 画像や動画など、コンテンツをデジタル化したもののURL
 - ▶ デジタルコンテンツURLは複数となる（さらに提供者も複数）場合もある
- デジタルコンテンツ利用のための技術情報（フォーマットなど）
- デジタルコンテンツ利用のためのライセンス情報

11 提供/ソース関連の共通情報表示例

w:accessInfo	schema:url	< http://www.narahaku.go.jp/collection/225-0.html >
	schema:description	"機関管理番号:225-0"
	v:contentHolder	d: 奈良国立博物館
	v:digitalObject	< https://colbase.nich.go.jp/uploads/collection_item_images/thumbnail/feb2ffccff8c589f119dd60ee8c5ebcf.jpg >
w:sourceInfo	id:p14813	
	rdf:type	c: アーカイブ情報
	schema:provider	< https://colbase.nich.go.jp/ > (ColBase:国立博...)
	schema:url	< https://colbase.nich.go.jp/collectionItems/view/5b7114ef7684b844c73356fa61c11915/225-0 >
	schema:dateModified	"1970/01/01"
schema:distribution	source:colbase-14813.json	

12 ライセンス情報の明示

■ コンテンツ自身のライセンス

- メディア芸術におけるライセンス記述の標準化と一括提供

■ デジタル化したコンテンツのライセンス（案）

- 提供元毎などに標準ライセンスを決めて一括記述
 - ▶ 統合プラットフォームで情報が得られるものは原則としてCC0にするなど
- 特別なライセンスが必要な例外のみ、オブジェクトの情報として記述
 - ▶ ブラウザなどでの表示の際には、標準ライセンスの場合もアイコンなどで明示する

■ メタデータに関するライセンス（案）

- 原則として共通情報はすべてCC0
- ソースデータも統合プラットフォームで提供できるものはCC0

13 共通情報整備の課題

■ データの品質と正規化

- 提供元データの記述方法のばらつき、表記の揺れについて、どこまで厳密に正規化するか
→ 発見タスク、特に「いつ」「どこで」「だれが」については可能な限り正規化し、URIとして扱う。Linked Dataも念頭に
- 識別、選択情報は原則として正規化せず、ソースデータを生かす
 - ▶ プロパティも無理にマッピングせず、汎用プロパティに導入句付きの値で
- 単一フィールドに複数值が入ると正確な処理が困難
 - ▶ 区切り文字による複数值、（）を用いた読み、URLと表示名の併記など

■ 利活用のための提供データの調整と補完

- 名前（ラベル）は必須。提供されない場合はIDなどから生成する
- コンテンツの基本区分である**タイプ**は、選択のために必須。あらかじめ定義したタイプが提供される方向へ調整したい
- ライセンスは、提供元ごとに基本（デフォルト）ライセンスを設定したい
- 場所情報はサンプルデータでは提供例が少ないが、利活用に有益。提供機関の所在地を適用することも