

## 画像ベース電子図書館用 Metadata モデル(ETO)の提案

5P-6

大矢 一志<sup>1</sup>

丸善株式会社

千葉大学大学院自然科学研究科

土屋 俊<sup>2</sup>

千葉大学文学部

### 1はじめに

電子図書館が現実のインフラとなるには、始めから電子化された情報の他、既存の図書館が所蔵する書籍や絵画等を電子化し、それらを統一的に扱う必要がある。その場合、既存の情報は画像データとして扱われ、メタデータベースで管理される。但し、MARCは書籍ベースで作成されている為、操作対象となるデータ単位はシステム完成後、日常的に細分化される。例えば、論文集は各論文毎で操作対象となるのが望ましく、それに必要なメタデータを作成しデータ単位を細分化することになる。

一方、データ単位に変更があっても、外からの参照に対しては当該データ単位へのアクセスを保証し続ける必要がある。これには、所在に依存しない抽象名が有効であるが、それだけでは情報単位の細分化に対処できない。

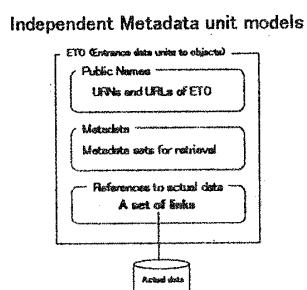
また図書館は、この様な情報提供サービスという個人に対するサービスの他、保存すなわち文化の資産化という、社会に対するサービスを行う義務がある。電子図書館でもこれに変わりはない。従来の情報資産に匹敵するデータ寿命が求められる。従って、データは可能な限りアプリケーション独立が求められ、それにはテキストベースデータモデル(TBDM)の利用が望ましい。膨大なデータをTBDMで表現する場合、現実にはデータそのものの管理用とデータ提供用のシステムを分ける必要がある。

本稿では、前者で利用されるメタデータモデルを提案する。

### 2 メタデータモデル:ETO

ETO(Entrance data units to objects)は、関連するデータ単位を宣言して、操作対象データ単位を構成するデータ単位である。文書の電子化並びにデータ寿命からして、データ表現にはTBDMを利用する。現行のTBDM用メタ言語SGML/XMLでは、中心となるデータ単位内で関連するデータ単位が宣

言される。この手法では、記述対象内容、メタ言語、これら各自のメタ記述の都合4レベルの内容が混合するため、データ寿命の点からすると望ましくない。ETOはこれらを中心となるデータから独立させ、その関連性を宣言する単位である。ETOは、以下の構成になる。



ETOは、自らが示すデータ単位の公開名と単位構成に関連するデータを宣言し、全てのデータ単位は、ETOを介して扱われる。Public Names部は、公開名が宣言され、URNとURLと検索用メタデータ(Core Metadata)を備える。Metadata部は、データタイプ毎の詳細なメタデータがリンクで示される。References部は、関連するデータ単位がリンクで示され、中心となる実データは埋め込み処理される。

### 3 要件

#### 抽象名サービス

TBDMにおいて、自らの同定手段は何らかの処理に依存せざるを得ない。そこで、少くとも環境から独立するには、URNの様な抽象名が必要となる。抽象名は、URNの他、必ずしもglobalで解決が保証されないローカル名も導入する。URNサービスとして、ETO用に拡張したTHTTPサーバ(cf.RFC2169、RFC2483)を想定している。

#### 検索用メタデータ

全てのデータ単位がETOを介してアクセスする為、データ検索に必要なメタデータをETO内に置く。これをCore Metadata(CMD)と呼ぶ。CMDはメタデータ項目の集合として、URNと同様、同定情報

A metadata model ETO for image-based digital libraries

<sup>1</sup>OHYA Kazushi, Maruzen co.,ltd., Graduate school of Natural Science, Chiba University

<sup>2</sup>Syuu Tutiya, Faculty of letters, Chiba University

の役割を果たす。具体的には Dublin Core を利用するが、多言語対応の為、属性 lang、script、notation と、下位要素 original、pronouncing、meaning を導入する。

#### 画像データ

画像データは、実データであるテキストデータ中にリンク要素として記述される。これにより、記述の線状性を使用し、その連続する構造が容易に示され、必要とあれば TBDM の構造を利用して構造を示すことが可能である (cf. TEI P3)。また、実データを分離し、ETO によってその独立単位を保証することが出来る。

```
<imgList>
<表><img name="urn:local:mm001:1"/>表1<img name="urn:local:mm001:2"/>表2
<見返し><img name="urn:local:mm001:3"/>見返し<白><img name="urn:local:mm001:4"/>白
<履り><img name="urn:local:mm001:5"/>履り<白><img name="urn:local:mm001:6"/>白
<凡例><img name="urn:local:mm001:7"/>凡例<img name="urn:local:mm001:8"/>


```

#### 部分文書構造定義

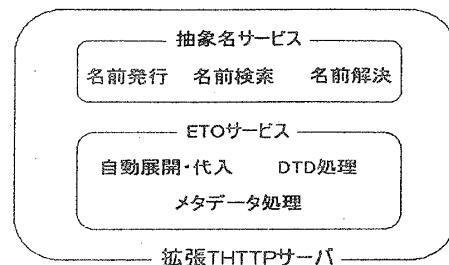
ETO は実データへの参照情報のみを持ち、利用時にそれを展開し埋め込む。ETO は複数の ETO を並列的階層的に参照できることから、部分単位毎に異なる文書構造を宣言する必要がある。それに伴い、現行の規格 SGML/XML の規格を拡張する。任意の所で要素・属性宣言を可能にし、そのスコープとして local、global、ptl(priority to the last) の 3 つを導入した。現状のブラウザで用いる際には、ETO サーバ側でデータ中の全ての宣言を外し well-formed とするか、ひとつの DTD をまとめる。

#### リンクと処理

情報単位が細分化すると、ETO と最終実データとの間に複数の ETO が介在する。これら ETO は全て自動展開することが望ましい。但し、細分化の階層を先読みせずに指定できることが望ましい。そこで、リンクと「処理」の関係を整理し、処理との関連性を生む「リンク活性」を、再帰的に指定する属性 activate を導入した (cf. 大矢・土屋 1999)。

#### 4 ETO を用いたシステムの概要

ETO を用いたデータ保存・管理支援サービスは、「抽象名サービス」と「ETO サービス」から成る。前者は、抽象名の発行・確認・解決を行い、後者は、リンクの処理指定の代行、部分的構造宣言の処理を行う。検証用プロトタイプを、THTTP サーバを拡張して作成した。



ETO を利用したシステムには、1) データ作成者の責任内でデータ間の構成情報も管理できる、2) 異なる書式のメタデータを利用できる、3) 実データを得ると同時に下位要素のメタデータ全てを獲得できる、4) データ単位の細分化を当該データ単位のみの変更で可能になる、という利点がある。

尚、今後の課題として以下がある。

#### 部分単位の独立性

TBDM の場合、従来基準であった「処理」をデータ独立の前提とし得ない為、新たな基準が必要となる。ETO が操作対象データの宣言としても、例えば、リンク要素の所在情報の書換えの際、部分要素を独立単位とするのは必要である。

#### リンクの定義

処理独立のデータモデルでは、全ての処理を記述する必要がある。処理の名前をどう付けるかの他、宣言方法が問題である。現行の PI は極めて直接的な処理指定を目的とする。対してリンクは「名前解決」と参照先との「関連性を何らかの処理で実現」という抽象的手順の総体である。関連性の表記法を統一させる意味では、リンクの利用が望ましい。但し、処理指定の関連事項、特に部分単位と、独立リンクと処理指定の場合、困難である (cf. 大矢・土屋 1999)。

#### Local URN の扱い

local 抽象名と global 抽象名 (URN) との関連が未定である。RDS の実体が不明である為、サーバ指定で local 抽象名が使えるという保証が無い。

#### 5 さいごに

本研究は、既存の図書館収蔵情報を含む電子図書館研究と共に、TBDM を利用したデータ作成の研究の取り掛かりとなった。

#### 参考文献

- [1] C.M.Sperberg-McQueen and L.Burnard ed., 1994, *The Guidelines for Electronic Text Encoding and Interchange (TEI P3)*, TEI
- [2] 大矢・土屋 1999 「複合データ単位に於けるリンク要素間リンクについて」 IPSJ SIG Notes, Vol.99 No.48, IPSJ