

2 Q-7 辞書ハイパーテキスト Hydra(1) —データベース構築手法—*

内藤 広志, 根本 治朗, 山下 真司, 松山 洋一, 棚木 孝一†
キヤノン(株) 情報システム研究所‡

1 はじめに

ノードとリンクからなる単純なモデルによって文書を表現するハイパーテキストが最近注目を集めている^[1]。この技術を用いて新しく文書を作成するだけでなく、既存のリニアな構造を持つテキストデータをハイパーテキストのノンリニア構造へ変換することは、過去の資産の有効利用のためにも重要である^[2, 3]。

そこで我々は、ハイパーテキスト技術の大規模データへの適用例として、辞書ハイパーテキスト Hydra (HyperDictionary Reading Accessories) の開発を進めるに同時に、そこから得られた知見に基づいて、大規模ハイパーテキストデータベースの構築手法について検討したので報告する。

2 データベース構築手法の概要

我々が Hydra の開発でとった構築手法を図示すると、図 1 のようになる。

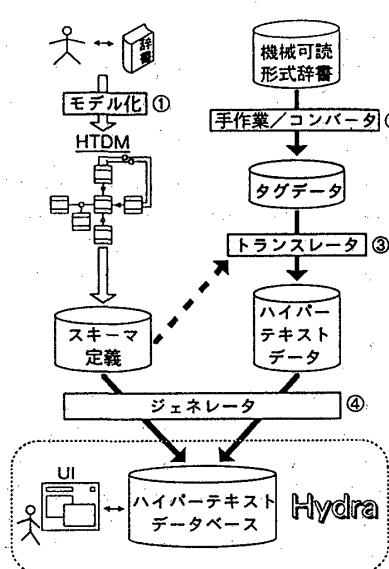


図 1: ハイパーテキストデータベース構築手法

この手法は次の 4 つのステップからなる。

1. 原データの分析とモデル化：原データの構造を分析し、ハイパーテキストデータベースの概念構造をハイパーテキストデータモデル (HTDM) によって表現する。
2. 原データの整形：機械可読形式辞書に対し、コンバータ／手作業を用いてタグ付けをする。

*The HyperDictionary Hydra (1) - Database Constructing -
†Hiroshi Naito, Jiro Nemoto, Shinji Yamashita, Yoichi Matsuyama,
Koichi Masegi

‡Information Systems Research Center, CANON Inc.

3. ノードへの分割とリンクの付与：ステップ 1 で記述された構造に基づいて、トランスレータによってノードへの分割とリンクの付与を行なう。
4. データベースへの格納：ジェネレータによって、データベースへの格納を行なう。

この手法の特徴は、データベース設計法や CASE で用いられている構造分析の考え方をハイパーテキストの設計に導入したことと、SGML を使用してハイパーテキスト構造を明示的に記述したことである。特に SGML を採用した理由は、データのシンタクスを明確に記述することに適していることと、今後 CD-ROM 等のデータ記述の標準として用いられることが期待されるからである。

3 ハイパーテキスト化の処理フロー

本章では Hydra の開発を題材に、既存データのハイパーテキスト化の処理フローについて述べる。

3.1 原データの分析とモデル化

機械可読形式辞書をハイパーテキスト化する際、単純に既存データに「反義」や「同義」などのリンク情報を付加するだけでは十分でない。フィルタや検索などにより効果的なナビゲーションをするためには、既存データをコンピュータ処理に適した形に構造化する必要がある。

そこで、我々はハイパーテキストのノンリニア性が表現可能なハイパーテキストデータモデル (HTDM) を設計し、これを用いて辞書のデータ構造をモデル化した^[4]。

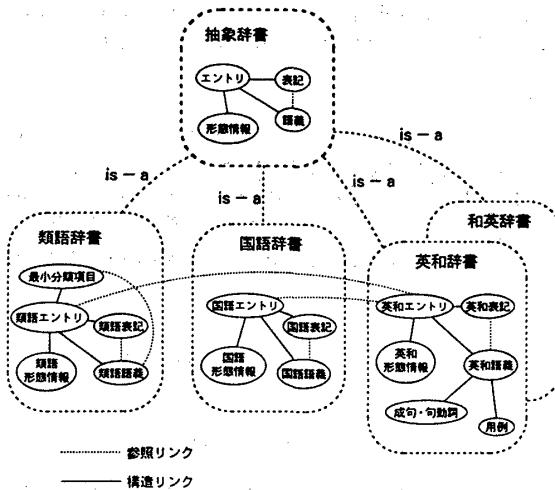


図 2: 辞書モデル

また、ただ単に個々の辞書をモデル化するだけではなく、様々な辞書構造を抽象化した辞書モデルを考え、個々の辞書はこれの特殊化したものと考えてモデル化した。これにより辞書データベースへの統一的なアクセス、複数辞書間のリンク、複数辞書のマージが可能となる。図 2 に抽象辞書モデルと個々の辞書の関係を示す。

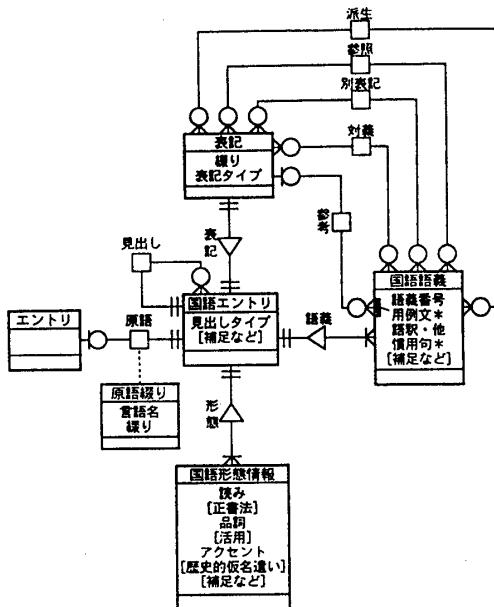
図 3 に HTDM を用いて国語辞典^[5]を記述した例を示す。

図 3: ハイパーテキストデータモデル

3.2 原データの整形

書籍形式の辞書をそのままコード化した機械可読形式辞書は、一定の文法に基づいて記述されているものの、それは人間が理解できることが目的であり、計算機で処理を行なうには厳密に欠ける^[6]。そのために各語彙毎に「アクセント」や「正書法」などの項目に分割し、各項目を識別するためのタグをつける必要がある。これを行なうのがコンバータである。しかし、原データには記述エラーも多いため、手作業で処理しなければならない部分が多い。図 4 は原データの機械可読形式辞書、図 5 はそれをコンバートした結果のタグデータである。タグデータは SGML を用いて記述される。

```
#ことば#3 [書葉] ([「は」は端の意])
 1) 社会ごとに決まっている、音声による表現(行為)。〔広義では、文字による表現(行為)をも指す〕「意味の分からぬ〔=単語〕・推論の一〔=文章〕・一を返す〔=A返答する〕B相手の言葉を反駁(ハンパク)する〕・〔=言い方〕が悪い・話し・書き・いなかー」
 2) 〔詞〕〔地の文に対して〕〔小説・戯曲の〕会話(文)。
.....
```

図 4: 機械可読形式辞書^[5]

3.3 ノードへの分割とリンクの付与

ハイパーテキスト構造を明示的にするために、トランスレータはタグデータ中の SGML でタグ付けされた項目をノード(オブジェクト)、属性、リンクに区別して記述し、ハイパーテキストデータとして出力する。その際、タグデータの構造も HTDM で記述されたノードの構造へ変換される。また、他のノードからの参照ができるためにノードへ名前が付けられる。一方、既存データ中に現れるリンクは、特定のノードそのものを示すものと、特定のキーを持つノード(の集合)を示すものがあるため、それぞれ個別のリンク、関数的リンクとして区別して記述される。図 6 は図 5 のデータをトランスレートした結果のハイパーテキストデータである。

```
<一般の単語>
<マーク>2
<見出しことば
<補足>
<ACC>3
<正書法>言葉
<補足的説明>「は」は、端の意
<語義><小語義>
<小語義番号>1
<小語義本体>
<語義文>社会ごとに決まっている、音声による表現(行為)。
〔広義では、文字による表現……
<用例等>意味の分からぬ〔=単語〕……
.....
</一般の単語>
```

図 5: タグデータ

```
<国語概念 label=ことば-1>
<形態><国語形態情報>
<読み>ことば
<正書法>言葉
<アクセント>3
<語義><国語語義>
<語義番号>1
<語訳・他>社会ごとに決まっている、音声による表現(行為)。
〔広義では、文字による表現……
<用例文>意味の分からぬ〔=単語〕……
.....
</国語概念>
```

図 6: ハイパーテキストデータ

3.4 データベースへの格納

HTDM で記述されたハイパーテキスト構造を基にデータベースの論理スキーマを設計することができる。ジェネレータは、SGML で明示的に構造が記述されたハイパーテキストデータを読み込み、DBMS に格納する。ジェネレータの処理は使用する DBMS のタイプ (RDB や OODB など) によって異なる。例えば、使用する DBMS が RDB の場合は、ノードやリンクをテーブルに変換し、それぞれに ID を付与し、参照関係を解決した後、DBMS へ格納する。OODB の場合は、ノードをオブジェクトに変換し、リンクはオブジェクトのインスタンス変数にストアする。

4 おわりに

現在開発中の辞書ハイパーテキスト Hydra を題材に、既存の大量データをデータベースに取り込む手法について述べた。大量データの処理はデータ表現法やツールの整備によって、作業指針を明確にしたり、自動化することが必要である。今後は作業の各ステップにおけるデータ表現の表現能力を充実させるとともに、ツール群を整備していく予定である。

参考文献

- [1] J. Conklin. Hypertext: An Introduction and Survey. *IEEE COMPUTER*, 2(9):17-41, 1987.
- [2] D.R. Raymond and F.W. Tompa. Hypertext and The Oxford English Dictionary. *Communications of the ACM*, 31(7):871-879, 1988.
- [3] L. Alscher. Hand-crafted Hypertext - Lessons from the ACM Experiment. In E. Barrett, editor, *The Society of Text*, pages 343-361. The MIT Press, 1989.
- [4] 根本治朗 他. 辞書ハイパーテキスト Hydra(2) — データモデル —. 情報処理学会第 42 回全国大会, 1991.
- [5] 金田一京助. 新明解国語辞典. 三省堂, 1989.
- [6] 鶴丸弘昭, 内田彰. 国語辞典からの情報抽出と構造化について. 長崎大学工学部研究報告, 15(24):41-48, 1985.