

古い著作物を分析するための計算機環境
—和歌文学を題材に—

2C-1

北村 啓子
国文学研究資料館 研究情報部

1. はじめに


古い著作物を計算機で扱うためにマルチレイヤ構造のマルチメディアデータモデルを提案している。ユーザインタフェースとしてのイメージデータ(筆記体の形状をそのまま保持)と計算機処理のための内部表現としてのテキストデータ(筆記体を活字に翻刻したテキスト; 複数種類のテキストがレイヤーを成す)の間で各レイヤの同じ箇所を同定しお互いに情報を補完しあうことを特長とする。イメージデータ-テキストデータ間のマッピングについては[1]で述べた。本論文では、古い著作物固有の特徴を考慮したマルチレイヤ構造のテキストについて述べる。また実際に和歌文学を題材として、テキストの表現方法とテキストを扱うために開発した基本的な処理ライブラリとそれらを利用した分析の例を紹介する。この環境はjperlで構築している。

2. マルチレイヤ構造のテキスト

国文学をはじめ古い著作物を対象とする分野一般の特徴として文字の認定、読み方の正解が無いという難しさがある。その要因として、古い著作物に本質的に存在するもの、古い著作物→翻刻→マシンリーダーダブルテキストのプロセスで発生するものなどがある。具体的に挙げると、

- ・読みが不明
- ・異表記が多い: 漢字/かな、異体字、同義文字、正字/俗字、新字/旧字
- ・異本による差
- ・句読点を使わない/使い分けしない

が大きな差を生んでいる。これらはテキスト検索をはじめあらゆるテキスト処理の精度を落す原因となる。これらの差を包含し表現する方法として図1に示すマルチレイヤ構造のテキストを利用することによりこの問題を解決する。



3. 古い著作物の構造

国文学が対象にしている古い著作物をテキスト処理するという観点で、和歌、散文、漢文/万葉仮名文、その他に大別する。それぞれの特徴とその構造を分析する。




図2 古い著作物の構造

○和歌:

図2に示すように物理構造が論理構造を表現している。特に単純な構造で扱いやすい堀川百首型と和歌一般型に分類する。和歌のように論理構造が明解である場合、次の2つのアプローチが考えられる。

a. 物理構造から論理構造を抽出

論理構造を処理プログラムに埋め込んでおくことにより物理構造から論理構造を抽出する。データ作成が楽で標準化の煩わしさもなく、見慣れた物理構造をしているので違和感がない。論理構造を示す物理構造の区切り(空行、改行、字下げ、下合わせ、etc.)を定義可能とすることにより、自由度を高くできる。

b. 論理構造のマークアップを定義

論理構造を明示するマークを決めてマーク付けを行う。標準化に伴う煩わしさがあるが、マークが標準化されると処理プログラムも共有できデータ互換性もある。標準化が進むとその分自由度は低くなる。マーク自身を定義可能とすることにより自由度を高くできる。

両者は逆のアプローチであるが、b.で定義したマークを物理構造の区切りに縮退したものと考え、両者を包含した高い一般化のテキスト表現が可能である。簡単な論理構造のものはa.のみで、複雑な論理構造のものは大まかな構造はa.を、細かな構造はb.を使った折衷が妥当と考える。

○散文:

図2に示すように、物理構造は文、段、章、巻で構成される。文については、句読点がないものも多く、句点と読点を区別していないものもある。その場合、句読点の正解は存在しない。散文の中の多くは物語であり、What(何を書いているのか)を明解には言えない。書誌情報(書名、著者名、etc.)以上の論理構造はなく、物語を分析するために意味ある論理構造のマーキングは困難であろう。

散文を分析するには、テーマに応じた機能語を使うことを考えている。例えば、

- 軍記物語: ~に~参じる、~に充滿す、~に著く、etc...
- を拾って登場人物の移動経路を辿っていく。または、
- 会話物語: ~曰く「~」、~と申す、~と仰る、etc...
- を拾って登場人物の会話集を作成するなどである。

○漢文、万葉仮名文: 漢字仮名混じり文に書き下して散文として扱う。

○その他: 謡曲(楽譜)、台詞(シナリオ)、絵文字や造字を使った物の一般化は困難。個々の対応を考える。

