

ODBと全文検索エンジンの連携による 人文系DB構築システムと電子図書館

丸 山 勝 巳[†]

国文学、史学などの人文系研究においても、本格的なデータベース構築とその検索閲覧サービスが望まれている。この分野では情報間の複雑なつながり関係や多様な非数值データの記録が要求されるので、表形式を基礎とする関係データベース（RDB）では扱い難い場合も多い。そこで、オブジェクト指向データベース（ODB）を活用してDB構築から電子図書館サービスまで統合したシステムを開発し効果を上げた。本稿では、(a) 情報間に複雑なつながりを含む人文系データベースのODBによる容易な実現、(b) 多数の一般ユーザに簡便な検索閲覧サービスを提供するために、ODB内容をSGMLファイル化して全文検索エンジンによりサービスする電子図書館システムの有効性、(c) 統合システム内インターフェースとしてのSGMLの効用、を具体的に述べる。

Humanity Database Compilation and Digital Library Service by Cooperating ODB and Fulltext Search Engine

KATSUMI MARUYAMA[†]

Even in humanity research fields, large scale Databases and Digital Library service are strongly required. In these fields, intricate inter-data relations and various non-numerical data are treated, and relational database (RDB) systems are sometimes not flexible enough to handle them. To answer these humanity requirements, an object-oriented database (ODB) system and a digital library system using a full-text search engine have been developed. It has been proved that (a) ODB is very suitable to handle mutually related humanity data, (b) a digital library system using an SGML-based full-text search engine is easy to use and convenient for public service, and that (c) SGML is a suitable interface to interwork an ODB system and a digital library system.

1. はじめに

国文学、史学などの人文系研究においても、本格的なデータベース構築とその検索閲覧サービスが望まれている。この分野のデータベースは、目録DB、数値文字DB、フルテキストDB、画像DBほか多種多様である。スプレッドシートや関係データベースが効果的に適用できるものも多いが、複雑なものになると固定的なスキーマでは扱い難い。また、特に資料と資料の間の関係を適切に表現でき、関連する資料を次々と効率良く検索できることが重要視される¹⁾。

また、大きなDBの内容構築は非常に大変な作業があるので、人文系の人にも使いやすいDB内容構築環境が重要である。さらにDBの検索閲覧に関しても、ネットワークを介してどこからもアクセスでき、だれ

でも簡単に検索でき、関連資料を効率良く検索しまわれるような検索閲覧サービス環境が望まれる。

著者は、巨大で複雑な内容を持ち、資料間の関係の表現が特に多いDBについて、オブジェクト指向データベースを適用したDB内容構築システムを開発して、その効果を確認した。また、このDBの検索閲覧サービスとしては、全文検索エンジンとインターネットWWW環境を利用したシステムを開発し、電子図書館サービスの一部に組み入れ、ユーザの好評を得ることができた。

本稿では、複雑な人文系DBを開発しようとする人の参考になるように、オブジェクト指向DBの利用例、DB構築環境およびDB検索閲覧サービス環境の実装経験を述べる。

2. 背景と新データベースの目標

国文学研究資料館（文部省大学共同利用機関）では、CTS（computer typesetting system）出版の内容作

[†] 学術情報センター

National Center for Science Information Systems

成のために、長年にわたって大型計算機と関係データベースシステムを用いて我国の古典籍に関する著者、著作、書誌のデータを蓄積してきている。その規模は約 400 MB（著者 7 万件、著作 43 万件、書誌 17 万件）に達する。ここに“著作”とは源氏物語といった作品を意味し、“書誌”とは各所で保存されている個々の写本、刊本を意味する。データは非常に項目豊富で込み入っており、たとえば書誌は書名、別書名、形態、書写者、出版者、注記、所蔵者など数十項目を持ち、その大部分は可変長文字列であり、繰返し項目も多く、また関連情報に結びつけるための情報も多い。

このシステムは CTS 出版が目的であったため、一般ユーザへのオンライン検索サービスの機能は持っていない。DB 構築環境もラインコマンドベースで今となっては旧態である。今回、メインフレームからワークステーションへの移行を機会に、システム機能としては以下の改善を行うことにした。

- DB の内容構築者のための環境（以降、“DB 構築環境”と呼ぶ）の抜本的改善。
- DB の内容利用者のための使いやすい環境（以降、“DB 検索閲覧サービス環境”と呼ぶ）の提供、特に電子図書館サービスとしての不特定多数への DB 検索閲覧サービスの提供や、DB 内容の CD-ROM 出版の容易化。

また、DB 内容としても、膨大な量の古典籍や著者の情報をいろいろな観点から容易に検索でき、自在にリンクをたどって関連情報にトラバース（traverse）ができる、そこからさらに原本画像や翻刻テキストも閲覧できる統合データベースとして抜本的に改善することとした。

たとえば、表題に“蝦夷”を含み種別が“地誌”的著作を検索すると該当する著作リストが表示され、その中の“北蝦夷図説”を見ると作品の詳細な情報、著者“間宮林蔵”的詳細情報にアクセスするための情報（これを以降リンクと呼ぶ）や個々の刊本の書誌情報へのリンクが表示されている。著者リンクを選ぶと、著者の詳細な情報や全作品へのリンクが表示され、またいざれかの書誌リンクを選択するとその刊本の書誌情報、所蔵者情報、原本画像や翻刻テキストへのリンクが表示される。原本画像リンクを選択すると原本画像を見る能够であるというようなシステムである。

DB 内容構築時にも DB 検索閲覧サービス時にも、このように検索論理式で目的物を検索し以降はリンクをたどってトラバースするといった使い方が多いので、関連情報のリンクを簡潔に表現できる DB でなければならぬ。

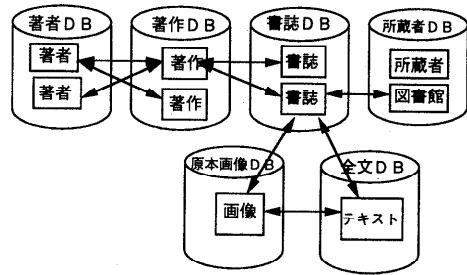


図 1 新データベースシステムの目標
Fig. 1 A new database system plan.

3. 本システムに対する要求条件

本システムに対する要求条件は、統合データベース化、DB 構築環境の改善、電子図書館サービスによる快適な DB 検索閲覧サービスの実現に大別される。

3.1 統合データベース化への要求

図 1 に示すように著者 DB、著作 DB、書誌 DBなどを含み、以下の機能を持つ統合データベースシステムを実現すること。

- 著者 DB は、本名、別称、職業、出身地、生没年などの著者情報を有する。将来は歴史人物をも含み系図なども追加して総合人名 DB に発展することとする。
- 著作 DB は、作品名、別書名、成立年、分類、注記などの著作情報を含む。
- 書誌 DB は、個々の写本や刊本の表題、内題、刊年、著者や書肆名、形態、所蔵者情報などの書誌情報を（個々の写本や刊本の属性）を含む。
- 著者と著作、著作と書誌の間などには両方向リンクが設定しており、たとえば著者情報、著作情報、書誌情報、所蔵者情報を、任意情報から始めてどちらの方向にも自在にたどれる。1人の著者が複数著作を持ちうるし、共著もあるので、これらのリンクは一般に多対多の関係である。
- 叢書、合綴など、1つの表題の中に複数の子作品が含まれるものがある。たとえば勅撰和歌集の二十一代集は、古今和歌集、後撰和歌集などの 21 個の歌集の総称である。また子作品も叢書であって、さらに子作品を含むこともある。このような親子関係を著作構造や書誌構造と呼び、相互にリンクでたどることとする。
- 原本画像 DB があり、個々の写本や刊本の書誌情報からは、その原本画像にリンクでたどれる。
- フルテキスト DB があり、個々の写本や刊本の書誌情報から翻刻テキストにリンクでたどれる。また、原本画像と翻刻テキストとは、ページ対応で

- 双向リンクが張られている。
- 書名、備考をはじめ大部分が可変長文字列フィールドで、かつ中間一致検索が頻用されるので、この検索が簡便で高速であること。

3.2 DB 構築環境への要求

DB 内容の構築者が、パソコン端末から LAN 経由で UNIX サーバ上の DBMS にアクセスして、新規データ入力やデータ修正が行える環境とする。この際の作業形態としては、以下の両手法が必要である。

- DB 構築端末から直接 DBMS に入力や修正を行うオンライン手法。
- DB 構築端末で入力データや修正データのファイルを作り、後で一括して DBMS に送るオフライン手法。

コンテンツ構築作業の効率化のために、使いやすい GUI (Graphical user interface) を持った端末プログラム（以下 DB 構築端末と呼ぶ）が必要である。

端末は、Windows, Macintosh, UNIX のいずれも使えることが望ましい。

3.3 DB 検索閲覧サービス環境への要求

電子図書館サービス^{2),3)}による多数ユーザーへの検索閲覧サービスは、本 DB の最重要目的の 1 つである。

人文系ユーザが対象であるので、検索は DB 内のデータ構造を意識せずに検索できること、複雑な検索論理式が不要であること、長文の中の部分一致検索が簡単で高速であること、関連項目へのトラバースが簡単で高速であることが必要である。

さらに、小中規模のサーバマシンで同時に多数ユーザーにサービス提供できることも必要である。

人文系研究者は自宅書斎で仕事をすることが多く、CD-ROM や印刷本としての出版も望まれるので、CD 出版や CTS 出版用にタグ付けした SGML⁴⁾ ファイルも出力できる必要がある。

4. システム設計方針

前述の要求条件に対して、以下の設計方針をとった。

4.1 DB 管理システム：オブジェクト指向 DB の利用

DBMS の種別としては、関係データベース RDB とオブジェクト指向データベース ODB とが考えられる。今回目標の DB は、原理的な表現力からいえば RDB でも対応できなくはないが、以下の理由で ODB を採用した。

- 本 DB の著作、書誌などの論理資料単位は、繰返し項目、可変構造項目などを含むので、RDB では複数テーブルを使った込み入った結合 (join) 操作が必要になるが、ODB では可変長配列や複合オブジェクトを用いて簡潔に表現できる。

- 本 DB は、関連資料間の多段にわたるリンクが頻繁に表現される（例：著者と著作の関係、著作と書誌の関係、叢書における親子関係、人物の系図など）。RDB では複雑な構造を持つ識別子キーが必要になるが、ODB ではオブジェクト間リンクとして直観的かつ簡単に表現できる。
- 本 DB では、関連資料間のリンクをたどるトラバースが頻繁に使われる。これは RDB では結合操作で実現できるが、人文系ユーザにとって検索式の記述が難しく、また計算機にとっても計算量の多い処理である。ODB では、ユーザは目的リンクを選定するだけでよく、計算機にとってアドレスをたどるだけの簡単な処理なので性能も上がる。
- 各オブジェクトクラスに特有な変換や操作をメソッドとして用意することで、高度の機能を使いやすい形で提供できる。

関係データベースにオブジェクト指向概念を追加したオブジェクト指向関係 DB (ORDB) も表現力は高いので候補となる。しかし、ORDB では応用プログラムは SQL-API を使ってデータベースにアクセスしなければならないので、プログラム記述が長くなる。これに対し ODB では、応用プログラムはデータベース内の永続オブジェクトも普通のオブジェクトと同様にアクセスできるので、プログラム記述が容易である。この理由で、本システムでは ODB である Objectivity/DB⁵⁾ を用いた。

4.2 DB 構築環境の構成

システム構成は、図 2 の左側に示すように UNIX サーバ上の DBMS とパソコンの DB 構築端末からなる Client-Server 型の分散システムとした。

DB 内容の構築者は、DB 構築端末の GUI を用いて以下作業ができるようにした。

- 新規データ入力とチェック：GUI の各項目に入力されたデータに対し、構文および値の厳格な検査を行い、DBMS に送る。
- 各種の検索と表示：DBMS にコマンドを送り、検索条件に合致したオブジェクトの表示や、リンクをたどった表示を行う。
- DB 修正：DBMS から読み出したデータを表示画面上で修正して返送することで、簡単に DBMS 内の既存データの修正を行う。

要求条件で述べたように、この際の作業形態としてはオンラインとオフラインの両手法をサポートする必

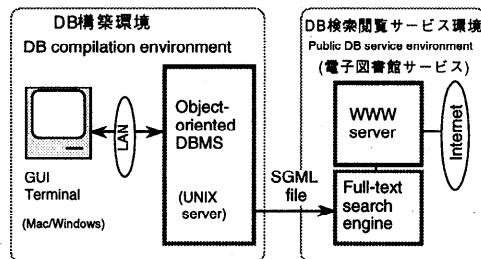


図 2 システムの全体像
Fig. 2 Total system outline.

要がある。そこで、DBMS と DB 構築端末は SGML⁴⁾でタグ付けした SGML テキストで通信しあうようにした。たとえば、DBMS は検索要求を受けるとその結果を SGML テキストに編集して GUI 端末に返送する。DB 構築端末はこれを受信して画面表示する。ユーザはその画面に修正を行ってただちに返送してもよく、また、いったんファイルに落として後でオフライン修正して DBMS に送ってもよい。DBMS から見れば、小さな SGML テキストが小刻みに送られてくるか、オフライン作成された大きな SGML テキストが一括して送られてくるかの差でしかなく、両者は同一処理で済む。

端末機種は Windows, Mac, UNIX が混用されているので、同一プログラムで全機種に対応させるために Java⁶⁾で開発することとした。

4.3 DB 検索閲覧サービス環境

本 DB の重要な利用の 1 つに、電子図書館サービスとしての多数ユーザーへの検索閲覧サービスがある。電子図書館サービス環境としては、インターネットの WWW 環境が適切な機能を使いやさしい形で提供しているのでこれを利用することとした。

電子図書館システムの WWW サーバの下で検索閲覧サービスを提供する手法としては、DBMS の検索機能を用いる方式と、全文検索エンジンを用いる方式とが考えられるが、以下の理由で図 2 の右側に示すように SGML ファイルを仲介とした全文検索エンジン方式とした。

- DB 構築者はデータ構造を意識した複雑な論理式検索も必要とするが、電子図書館サービスではデータ構造を意識せずにだれもが直観的に使える全文検索とトランザクションの方が好まれる。
- 電子図書館サービスでの検索では、完全一致よりも部分一致型の文字列検索が多用される。今回調査したオブジェクト指向 DBMS の文字列検索機能は、完全一致・前方一致はインデックス機能により高速化できるが、中間一致は高速化されない。

複数フィールドにまたがった検索は複雑な検索式が必要である。これに対し、全文検索システムならば、融通性も検索速度も満足できる。

- 構造化テキスト（たとえば SGML）対応の全文検索エンジンを使えば、簡単な検索式で文書構造に依存した検索も高速に行える。
- DB 内のオブジェクト間リンクを電子図書館ユーザのブラウザ上にハイパーリンクとして実現することで、関連情報の閲覧も容易に行える。
- CD-ROM/CTS 出版用の SGML ファイル作成プログラムに簡単な機能追加をするだけで、全文検索エンジン用の SGML ファイルを作成できる。
- 全文検索システムの方がより多数の同時アクセスに対応できる能力がある。
- データベース更新の結果は数時間で電子図書館サービスに反映できれば十分である。

5. DB 管理システムの実装

DBMS は、DB 構築端末の要求に応じてデータ入力、情報検索やトランザクション、データ修正、各種ファイルやリストの出力などを行う。また、メインフレーム上の既存 RDB からのデータ移植機能も含む。以下に実装技術を述べる。

5.1 スキーマとオブジェクト表現

本 DB の主要オブジェクトと、その間の主要なリンク関係を図 3 に示す。著者、著作、書誌といった主要な論理実体は、それぞれ Auth-obj, Work-obj, Biblio-obj と条件に応じて付加されたオブジェクトからなる複合オブジェクトとして表現されている。共通属性と拡張属性の関係は継承機能により簡潔に表現でき、RDB で面倒な繰返しフィールドも ODB では配

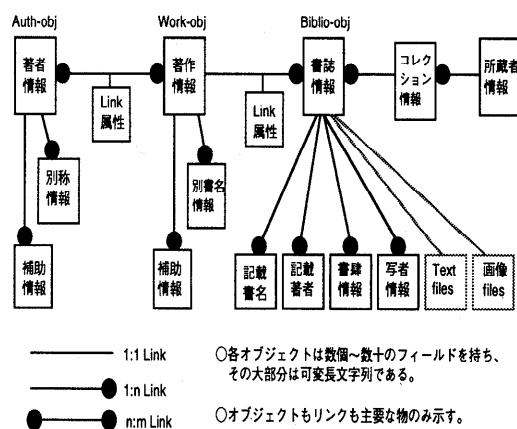


図 3 主要オブジェクトとその間の関係
Fig. 3 Main objects and their relationship.

列や集合として簡単に表現できる。

エンティティ間のリンクは、RDB では結合操作による間接表現となるが、ODB ではオブジェクトポインタで直接に表現できる。一般にオブジェクト指向 DBMS は、オブジェクトポインタを強化したアソシエーション (association) 機能^{5),12)} を持つておらず、これにより関連オブジェクト間を自在にたどれるリンクが組め、処理速度も速く、片方の修正を自動的に相手側に反映させてデータの一貫性も保証される。アソシエーションは 1:1, 1:m, m:n のすべての関係を表現できるので、図 3 に示すように、オブジェクトの相互関係が直観的に表現されている。たとえば、複数著作や共著の関係は m:n のアソシエーションとして表現される。

これらのリンク (DBMS 上ではアソシエーションで実現) は、DB 構築端末や電子図書館サービスのブラウザではリンクボタンとしてグラフィカル表示されており、クリックするだけで瞬時にオブジェクト間をトラバースすることができる (7 章参照)。

図 4 に簡略化したスキーマ定義とプログラム例を示す。ooRef() および ooHandle() は、Objectivity/DB のオブジェクト参照子を意味する。このように、DBMS 内の永続オブジェクトも普通のオブジェクトと同様にアクセスできる。Auth 定義の

`ooRef(Work) workLink[] <-> authLink[];`
と Work 定義の

```
class Auth: public ooObject {
    int aid;
    ooVString name;
    ooVString yomi;
    ...
    ooRef(Work) workLink[] <-> authLink[];
    ...
public:
    void Auth(char* _name ...)
    {
        ...
    }
    void setName(char* _name, char* _yomi)
    { name = _name; yomi = _yomi; }
    ...
}
```

(A) Author object

```
class Work: public ooObject {
    int wid;
    ooVString title;
    ooVString yomi;
    ...
    ooRef(Auth) authLink[] <-> workLink[];
    ...
public:
    void Work()
    {
        ...
    }
    void setTitle(char* _title, har* yomi)
    { title = _title; yomi = _yomi; }
    ...
}
```

(B) Work(作品) object

```
ooHandle(Auth) a1; // Author object handling
a1 = new Auth();
a1->setName("紫式部", "むらさきしきぶ");
...
ooHandle(Work) w1; // Work object handling
w1 = new Work();
w1->setTitle("源氏物語", "げんじものがたり");
...
w1->add_authLink(a1); // Associate "w1" and "a1"
```

(C) Object handling example

図 4 永続オブジェクトの定義と操作

Fig. 4 Persistent object definitions and operations.

`ooRef(Auth) authLink[] <-> workLink[];` は、著者と作品がフィールド Auth::workLink と Work::authLink によって相互関連していることを示す。配列記号 [] は複数収容を示すので、これは m:n 関係を意味する。

5.2 DB 間の関連情報リンク設定処理

本システムでは、著者 DB、著作 DB、書誌 DB の個別 DB にデータ入力が済んだ時点では各 DB 内に閉じたリンクのみが設定されおり、DB 間にまたがったリンクは未設定である。たとえば、著作 DB 内の “源氏物語 obj” には《name=“紫式部”, yomi=“むらさきしきぶ”》などの “相手検索情報” が記録されているのみである (相手検索情報としてはその他の属性も使われる)。

そこで、著作 obj に対して、著者名などの相手検索情報で著者 DB を検索して目的オブジェクトを見つけてリンクを設定するのが本処理である。この際に、相手検索情報を満足するオブジェクトの検索結果としては、以下の 4 ケースがある。

- ユニークに決定。
- 複数候補あり (たとえば同名の著者)。
- 類似候補あり (たとえば表記と読みのうち、一方だけが一致の場合)。
- 候補なし。

DB 構築者は、この結果を見て正しいものを選択したり、誤データの修正や不足データの入力をしたりする必要があるので、この作業の容易化が重要である。

このため、DBMS の DB 間リンク設定処理は、“リンク先候補検索フェーズ”と、“リンク設定実行フェーズ”的 2 フェーズで行っている。リンク先候補検索フェーズを実行すると、DBMS は検索結果を SGML テキストに編集して DB 構築者に報告する。この SGML テキストには、《リンク元の主要フィールドの内容とこのオブジェクトの ID 番号》と、リンク先候補の個数分の《リンク先候補の主要フィールドの内容とそのオブジェクトの ID 番号》とが対応して記録されており、DB 構築者はこの SGML テキストを見て、次の処理を行う。

- 候補がユニークに決定の場合は、それが正しい相手ならば了解マークを記す。正しい相手でないとしたらデータのエラーや未入力なので、データの修正もしくは新規入力を行う。
- 候補が複数の場合は、その中から正しい相手に了解マークを記し、それ以外は SGML テキストから削除する。
- 類似候補の場合は、データのエラーや未入力な

で、データの修正もしくは新規入力を行う。

- 無候補の場合は、リンク先オブジェクトが未入力なのでそれを新規入力する。

このようにデータ修正を行い、編集した SGML テキストを DBMS に返送して再度リンク先候補の検索を行う。すべてがユニークに決定できるようになったら、リンク設定実行フェーズを起動して実際に DB 間リンクを設定する。

人文系のデータベースでは関連情報を見つけてリンクを設定したいことが多いので、この類似候補検索を強化するといろいろな発展が可能であろう。

5.3 目的別出力ファイルの生成

本システムは、電子図書館システムの全文検索システム用にタグ付けした SGML ファイル（7章で説明する）、CD 出版や CTS 出版用にタグ付けした SGML ファイル、plain text ファイルなどを出力できるようにした。もちろん、検索条件に一致したものだけを出力することも可能である。

データベースに SQL-API で間接アクセスしなければならない RDB と違って、ODB では応用プログラムが直接データベースにアクセスできるので、簡単なプログラムで要求に応じたファイルを作ることができた。

6. DB 構築端末の実装

6.1 SGML テキストによる DB 構築端末と DBMS 間通信

4.2 節で述べたように、DB 構築端末はデータ構造や項目をタグで表現した SGML テキストでもって DBMS と交信する。これにより、DB 構築端末側ではこの SGML テキストをオンライン処理することも、ファイル化してオフラインで一括処理することも可能である（図 5）。DB 構築端末は以下の機能を持つ。

- 新規データ入力モードでは、DB 構築端末は入力データの形式と値の正当性をチェックし、SGML テキストに編集して DBMS に送る。
- 検索命令やトランザクション命令を DB 構築端末から DBMS に送ると、DBMS は結果を SGML テキストに編集して DB 構築端末に返送する。DB 構築端末はこれを GUI 表示する。
- 更新モードにて DB 構築端末の表示画面に修正を施して送信すると、新データが SGML テキストとして DBMS 本体に送られて DB が仮更新され、Commit/Abort 時に本更新が行われる。

6.2 Client-Server 構成による DB 構築端末の実装

DB 構築端末プログラムは、日本語対応の Java 開

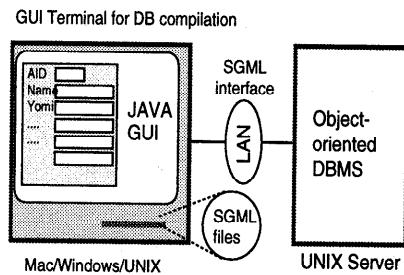


図 5 DB 構築端末
Fig. 5 GUI terminal for DB compilation.

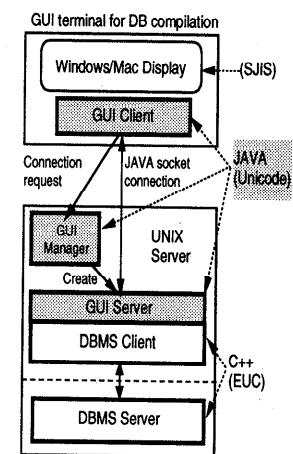


図 6 DBMS と DB 構築端末の機能配分
Fig. 6 DBMS and GUI terminal interworking.

発キットを用いて実装した。複数の DB ユーザがパソコンから LAN 経由で UNIX サーバ上の DBMS にアクセスするので、GUI プログラムはユーザ PC 上で走る GUI Client と、UNIX サーバ上で走る GUI Server から成る構成とし、その間の通信には Java の Socket を用いた（図 6）。

ユーザの DB 接続要求は GUI Manager に送られる。GUI Manager は GUI Server の生成と DBMS Client の起動を行い、GUI Client と DBMS とを結び付けるので、GUI Client の数だけ GUI Server と DBMS Client が動的に生成される。

ここで DBMS (Objectivity/DB) 自体も Client-Server 型であり、DBMS Server と DBMS Client は分散配置が可能があるので、データベースがさらに大規模になったら 3 階層の分散システムとしても運用できる。

日本語を扱う場合、文字コードは重要な問題の 1 つである。本システムでは図 6 に示すように UNIX 部は EUC、PC 部は SJIS、JAVA 部は Unicode というように 3 種類のコードが共存している。Java の入出

力機能は文字コード名を指定するだけでコードの自動変換ができるので、本システムの開発においてはコード変換を意識する必要はなかった。ただし、外字を使う場合には各々の外字を定義する必要があるので、今後 Unicode 環境が整備されたら Unicode で統一した方が良いと考える。

7. 電子図書館用の検索閲覧サービスシステムの実装

前述のように、電子図書館システムにおける DB 検索閲覧サービスシステムは、DBMS が作成した SGML ファイルを全文検索エンジンで検索し、結果をユーザに返送する。全文検索エンジンでは、高速検索を可能にするためにあらかじめバッチ作業でインデックス情報を作っておく必要がある。全文検索エンジンは、分かれ書きや形態素解析に基づいてインデックス情報を生成するものが多いが、古文の場合は辞書が整備されていないため形態素解析はうまく動作しない。したがって、分かれ書きや形態素解析に依存しないインデックス方式が必要である。また文書構造を指定した検索を可能とするために SGML 対応が望まれる。この両条件から全文検索エンジンとしては OpenText⁷⁾ を使用した。

前述のように、電子図書館サービスの環境には WWW 環境を利用しているので、WWW サーバが全文検索エンジンを制御する。

7.1 電子図書館サービス用の SGML ファイル

全文検索エンジン OpenText を使うには、まず(1) SGML ファイル (SGML タグ付けしたテキストファイル) を用意し、次いで(2) OpenText のインデックス作成機能を用いて、SGML ファイルからインデックスファイルを作つておく (バッチ作業) 必要がある。後は、OpenText に検索コマンドを与えると、OpenText はインデックスファイルを用いて該当箇所を高速に探し当て、その内容を SGML ファイルから出力したりする。RDB の SQL が検索式の中にフィールド名などを指定できるように、OpenText の検索コマンドは、検索箇所や文脈などを SGML タグを用いて指定することができる。

この全文検索用 SGML ファイルは、オブジェクト指向データベースの内容から以下のように作成する。

- 本データベースは、著者 DB、著作 DB および書誌 DB から成るので、各々に対応した 3 個の SGML ファイル (著者 SGML、著作 SGML、書誌 SGML) を作成する。
- 本 DBMS 内では、"著者 obj" とその著者の "著

```
<!-- SGML テキスト例 -->
<auth>
<aid>1234</>
<name>紫式部</>
<yomi>むらさきしきぶ</>
.....
<work>
<worklink wid=8765>源氏物語</>
<worklink wid=9876>紫式部日記</>
.....
</work>
.....
</auth>
```

図 7 電子図書館用 SGML テキストでのハイパーリンク
Fig. 7 Hyperlink in SGML text for Digital Library.

作 obj" がアソシエーション機能でつながれているように、関連オブジェクトは著者 DB、著作 DB、書誌 DB といった DB の枠組みを越えて双向リンクを組んでいる。SGML ファイル上では、これらを後述の手法で SGML ファイル間リンクに表現します。

- 図 3 に示すように、たとえば著者オブジェクトは、複数の別称オブジェクトなどを抱えている (複合オブジェクト)。電子図書館サービスでは、DBMS 内のオブジェクト単位に表示するよりも、別称は著者情報内に入れ子で表示したほうが読者に便利である。したがって、このような DBMS 内の複合オブジェクトは、SGML ファイルでは入れ子表示に変換する。

著者ファイルの SGML テキスト例を図 7 に示す。このように SGML ファイル間のリンクは、単純にリンク先情報の ID 番号を用いて、たとえばリンク先が著作情報でその ID (wid) が 8765 の源氏物語だとしたら、"[<worklink wid=8765>源氏物語</>](#)" と SGML 表現している。

電子図書館サービスのユーザが、リンク先情報へのトラバースを指令すると、全文検索エンジンはこの ID を用いて検索するが、インデックスファイルが作られているので高速に検索が完了する。

DBMS から著者・著作・書誌の各 SGML ファイルを作り、これに検索用インデックス情報を生成する作業は、1 つのシェルコマンドで行える。SGML ファイルの合計規模は約 400 MB であるが、SGML ファイル作成の所用時間は約 30 分、インデックス情報生成の所用時間は 4 時間強であった (Sparc Server 1000)。

7.2 処理の流れと CGI

電子図書館システムでの処理は、図 8 に示すように汎用 WWW サーバ、CGI (Common Gateway In-

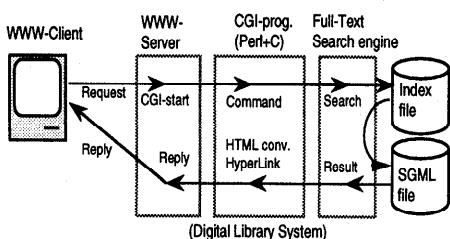


図 8 全文検索エンジンを使った電子図書館サービス

Fig. 8 Digital library service using Fulltext search engine.

terface program)⁸⁾ と全文検索エンジンによって行われる。

CGI は以下の処理を行う専用のプログラムで、Perl⁹⁾ と C で記述した。サイズは各々 400 行と 1400 行程度である。

- 入力情報を分析し、検索コマンドを編集して全文検索エンジン OpenText を起動する。
- OpenText が返した SGML テキストに対し、WWW サービスのための HTML タグの追加、SGML → HTML タグ変換、ヒットした検索語を着色表示するタグ付けなどを行う。
- WWW 上でハイパーリンクを実現する。前節のように SGML テキスト上ではハイパーリンクは相手オブジェクトの ID 情報として表現されている。これを該当オブジェクトを検索する CGI コマンドのリンクに変換する。たとえば、<worklink wid=8765>源氏物語</> を 源氏物語</> という形式の HTML タグに変換する。これは「search という名前の CGI プログラムをパラメータ wid=8765 で実行せよ」を意味し、ユーザがブラウザ上でこのリンクをクリックすると、wid=8765 のオブジェクトが検索され表示される。

8. 関連研究

本システムは、情報間の関連の表現に重きを置いた込み入った内容を持つ人文系 DB への ODB の活用、全文検索エンジンと SGML テキストを活用した電子図書館サービス、SGML テキストによるシステム間の結合に特徴がある。

通常の目録 DB は目録レコードの集合であり、レコード間の関係も複雑でないので RDB の特性にあっており、大部分は RDB によって実現されている。これに対し、本システムは著者 DB、著作 DB、書誌 DB といった自己完結的な DB の集合で、DB 内および

DB 間の関連するオブジェクトが相互にリンクを張り合っていて自在にトラバースできるもので、ODB を用いてこそ簡単に実現できたといえる。

電子図書館システムの研究は各地で行われているが^{2), 10), 11)}、本報告のように古典籍を対象として著者・著作・書誌・原本画像などの間を自在にトラバースして検索閲覧することをねらったシステムは見当たらぬ（原本画像 DB は別途検討が進んでおり、将来結合する予定である）。オブジェクト指向 DB に記録された込み入った内容を SGML テキストに変換し、それを全文検索エンジンを用いて電子図書館サービスする点も独特である。全文検索エンジンによる非常に簡便で高速な検索は、電子図書館ユーザである国文学者に好評である。

フルテキスト閲覧サービスに関しては、SGML テキストと全文検索エンジンの組合せによるサービスが今後が広まるとと思われる。なお、図面を持つ科学技術論文の閲覧サービスに関してはページイメージが主流といえる。

9. 評価

9.1 ODB の有効性

元情報が持っているデータ間の関係をダイレクトにオブジェクト間のリンクとして表現でき、直観的に目的データにアクセスできるので、人文系 DB のように関連情報間のつながり表現を重視する場合には効果的である。特にアソシエーション機能は適切にオブジェクト関係の表現とデータ管理を可能とする。たとえば、国文学者に RDB のテーブル図を理解してもらうのは必ずしも容易ではないが、図 3 のようなオブジェクト関連図ならただちに理解してくれた。

現在の DB 内容はメインフレーム上の RDB から移植したものである（約 400 MB）が、RDB よりも格段に使いやすくなった。また、SQL-API を経由せずに応用プログラムから直接 DB にアクセスできることによるプログラム開発の容易化も大きい。

本 DB システムの永続オブジェクトは、クラス数が 19、フィールド合計が 220 である。本体プログラムは既存データ移植や電子図書館用機能まで含めて約 18K 行 (C++) であり、1.5 人年程度で開発できた。

なお、人文系 DB には RDB で適切に表現できるものも多くあり、問題内容に応じて RDB と ODB を使い分けねばよい。

9.2 ODB と標準化

RDB に対し ODB の標準化の遅れを懸念する意見も聞かれるので、Objectivity/DB 用プログラムの一

部を別の ODB である ObjectStore¹²⁾ 用プログラムに書き換える実験を行った。その結果、プログラム開発が RDB よりも格段に容易なので、異機種 ODB へのプログラム書き換えも比較的容易であることを確認できた。データ自体は SGML 化テキストファイルとして簡単に移植できる。

9.3 DB 構築端末プログラムの JAVA による実装

日本語対応の Java 開発キットを用いて実装した。豊富なクラスライブラリーのおかげで、GUI 表示、DB 修正のための表示内容の編集機能、DBMS との通信などを含めて約 3K 行で実現できた。同一バイナリコードで Windows および Unix が走り、日本語の入出力もできるので、JAVA の採用は効果的であった。

9.4 電子図書館としての使い心地

本電子図書館サービスのユーザは、WWW ブラウザから著者 DB・著作 DB・書誌 DB のいずれかを指定し検索語を入力するだけで、それを含むオブジェクトが表示され、またリンクボタンをクリックするだけで関連情報に自在にトラバースでき、非常に簡便に必要な情報にアクセスできる。検索も短時間で処理できる。たとえば、書名に“源氏”を含む作品を検索すると、約 14 秒で 1111 件が表示される（内訳：OpenText：1 秒、CGI：5 秒、NW 転送：9 秒）。CGI に時間がかかるといふが、これは Perl 記述部のコンパイル時間と実行時間なので、C 言語などで書き直せば高速化できる。

DB 構築端末から ODBMS を直接検索した場合は、複雑な検索式を入力すれば大変込み入った情報検索も 1 回の検索で行える、数値演算をともなう検索が可能であるなど、より強力な検索が行える（なお、本 DB では数値演算対象のデータはほとんど含まない）。文字列の検索速度に関しては、完全一致と前方一致検索は OpenText 同等に高速であるが、中間一致検索は数分かかることがある。

10. おわりに

人文系データベースといつても多様であるが、その中で情報間の複雑な相互関係や込み入ったデータ構造を扱わなければならない場合には、ODB の特徴融通性は非常に有利である。また、この内容を電子図書館サービスとして使いやすい検索閲覧サービスを提供するには、全文検索方式が効果的で、実際にユーザの評判も良い。大多数の ODBMS は高速全文検索機能を含んでいないが、ODBMS と全文検索エンジンは SGML ファイルを介させることで簡単に協調動作させることができる。

今後の課題は、原本画像や本體テキストとのリンク、複数図書館にまたがった分散サービスの実現、ネットワークを利用したデータベース内容の分散協調開発環境の実現があげられる。

本システムの電子図書館サービスは、書誌情報（SGML テキストで 162 MB）に関しては著作権や原本所蔵者の公開許諾などの課題があるため、外部には著作情報（同 224 MB）と著者情報（同 38 MB）のみを <http://www.nijl.ac.jp/infocenter.html> にて公開している。

参考文献

- 1) 八村広三郎：人文科学とデータベース、情報処理、Vol.38, No.5 (1997).
- 2) 長尾ほか：電子図書館 Ariadne の開発、情報管理、Vol.38, No.3 (1995).
- 3) ACM: Digital Libraries, *Comm. ACM*, Vol.38, No.4 (1995).
- 4) Bryan, M.: *SGML 入門*、アスキー (1991).
- 5) Objectivity Inc.: *Objectivity/DB* 説明、<http://www.ogis-ri.co.jp/otc/products/objectivity/technical.html>
- 6) JavaSoft Inc.: *JAVA online documents*, <http://www.javasoft.com/>
- 7) OpenText 社：*OpenText* 説明書、<http://www.opentext.com/>
- 8) The WWW Consortium: *HTTP online documents*, <http://www.w3.org/>
- 9) Warry, L., et al.: *Programming Perl*, O'Reilly and Associates (1993).
- 10) デジタル図書館学会：デジタル図書館ネットワークホームページ、<http://www.DL.ulis.ac.jp/>
- 11) 安達：学術情報センターのデジタル図書館プロジェクト、情報処理、Vol.37, No.9 (1996).
- 12) 石塚：オブジェクト指向データベース、アスキー (1996).

(平成 10 年 8 月 13 日受付)

(平成 11 年 1 月 8 日採録)



丸山 勝巳（正会員）

1970 年東京大学大学院工学系研究科電子工学専攻修士課程修了。同年電電公社（現 NTT）入社。1995 年国文学研究資料館教授。1998 年学術情報センター教授。高水準言語、最適化コンパイラ、実時間システム、並行オブジェクト指向、分散 OS、電子図書館、ODB 等の研究に従事。1982 年電電公社総裁表彰。1993 年本学会論文賞。1997 年電気通信普及財団賞。工学博士。