

# SEQUEL について

渋谷政昭, 鷹尾洋一  
(日本 IBM Scientific Center)

## 1 まえがき

データ・ベースの関係形式 (Relational Model of Data Base) は、より広汎な末端使用者が、データ・ベースの物理的環境やファイルへのアクセス方法を意識することなく、これらに依存しない言語によって照会を行なうためのモデルである。プログラマー以外の利用者が、ときどきデータ・ベースを利用できるようにするためには、このようなデータ・ベースのモデル化に対応して、照会言語も単純でありなじみ易いものである事が要求される。(照会のための言語は、一般の計算言語に比べて、限られた表現能力しかもたないため、データ準言語—data sublanguageと呼ばれる。) この方向の努力の一例として、IBM San Jose Research Laboratory において研究開発されている SEQUEL (Structured English QUERY Language) システムについて紹介する。なお、関係形式そのものについては、文献 [1, 2, 3] を参照されたい。

データ・ベースの関係形式が E.F. Codd より提唱されて以来、彼自身により、また他の人々により、そのためのいくつかのデータ準言語が提案されてきたし、これからもまた新しい提案がなされるであろう。SEQUEL の紹介に入る前に、これらについて簡単に説明しておく。

### a) 「要素操作型」

PL/I 等の汎用言語を親言語として用いられることとを目的としており、基本的な少数の機能を用意すればよい。すなわち、1つの関係形式を探査して、与えられた条件を満たす  $n$  個組 ( $n$ -tuple) を逐次取り出す事ができればよい。例として GAMMA-0 [4] があり、また後で紹介する XRM もこの型の interface を提供するものである。

### b) 「代数型」

照会という操作は、データ・ベース内の関係形式 (一般に複数個) から、目的とする関係形式を作り上げる過程である。代数型言語では、和、差、積、直積、射影、結合、商などの集合論的な演算を用いて、関係形式を代数的に結合してゆき、照会を記述する。

### c) 「写像型」

$m$  項関係は、2項関係の拡張として、その domain の任意の部分直積から他の部分直積への写像をすべて表現していると考えることができる。このような写像と *and*, *or* より照会を行なうものである。例としては、SQUARE [5] があり、SEQUEL はその変種とみなすことができる。

### d) 「述語論理型」

検索の条件を述語論理の形式で記述するもので、当然、記述の明確さ、确实さという点では最も秀れている。一般利用者にとっては、必ずしも、なじみやすさの点ではないが、述語論理で難解なような内容を、他の型で、分かり易く、しかも曖昧さを残さずに表現することも困難であろう。

例としては、ALPHA [6] があげられる。

## 2 SEQUEL による照会 [7]

SEQUEL システムにおける照会の機能を、例を用いて紹介しておく。  
ここで、データベースは次の関係形式から成っているものとする。

```
EMP (MNO, ENAME, SAL, MGR, DNO)  
DEPT (DNO, DNAME, LOC)
```

関係形式 EMP は、すべてへ社員について、社員番号 (MNO)、名前 (ENAME)、給料 (SAL)、上司の社員番号 (MGR)、それと所属部門コード (DNO) と与える。また、DEPT は、すべての部門について、部門コード (DNO)、部門名 (DNAME)、それと所在地 (LOC) と与えるものである。

まず、SEQUEL における最も簡単な照会例を示す。

Q1. 「所在地が NEWBERG である部門の部門コードを示せ。」

```
SELECT DNO  
FROM DEPT  
WHERE LOC='NEWBERG';
```

FROM 節で検索すべき関係形式名を指定し、WHERE 節では検索条件を指定する。また、SELECT 節では、検索された n 個組のどの domain の値を出すか指定する。SEQUEL では、この最も簡単な照会形式を「ブロック」と呼ぶ。

WHERE 節には、いくつかの検索条件を AND, OR で結合しただけで指定することも可能である。

Q2. 「所属部門コードが 19 で、給料が 15000 以上の社員名とその上司の社員番号を示せ。」

```
SELECT ENAME, MGR  
FROM EMP  
WHERE DNO=19  
AND  
SAL>15000;
```

また、WHERE 節を省略することもでき、その場合々は、関係形式代数の影射 (projection) を行なうのと同様になる。

Q3. 「社員の名からわかる部門コードをすべて示せ。」

```
SELECT DNO  
FROM EMP;
```

特定の domain の値ではなく、n 個組全体を取り出しただけの場合には、「SELECT \*」という省略表現を用いることができる。

Q4. 「給料が 20000 以上である社員に関するすべての情報を示せ。」

```
SELECT *  
FROM EMP  
WHERE SAL>20000;
```

SELECT 節には、検索結果への操作をほどこすため、SEQUEL が用意している組込関数を指定することもできる。使用可能な組込関数は、SUM, COUNT, AVG, MAX, MIN の 5 種類である。

Q5. 「所属部門コードが 17 である社員の平均給料を示せ。」

```
SELECT AVG(SAL)  
FROM EMP  
WHERE DNO=17;
```

WHERE 節に書ける検索条件は、比較演算子を用いた条件とは限らない。  
ある domain の値が、特定の範囲内にあることを条件とする場合は、WHERE 節  
に "d BETWEEN v<sub>1</sub> AND v<sub>2</sub>" という形で書くことができる。

Q6. 「給料が 10000 から 20000 の範囲内にある社員の名前を示せ。」

```
SELECT ENAME
FROM EMP
WHERE SAL BETWEEN 10000 AND 20000;
```

また、"d IN v" という形で、ある domain の値が、ある集合の要素となる  
ことを条件として設定することができる。

Q7. 「所属部門コードが 17 か 24 か 32 である社員の名前を示せ。」

```
SELECT ENAME
FROM EMP
WHERE DNO IN (17,24,32);
```

この機能を用いると、さらに、下を示すように、ブロックのネストが行なえる  
ことになる。

Q8. 「所在地が NEWBERG である部門に所属している社員の名前を示せ。」

```
SELECT ENAME
FROM EMP
WHERE DNO IN
  (SELECT DNO
   FROM DEPT
   WHERE LOC='NEWBERG');
```

さらに複雑な照会を行なう場合は、2つの関係形式によって、複数個の domain  
に関して連関 (association) をとる必要が生ずる事がある。すなわち、2つの、  
ブロックの検索条件が互いに他を参照する様の場合である。SEQUEL では、  
組変数 (tuple variable) の導入により、この種の照会が可能となる。

Q9. 「給料がその上司の給料以上である社員の名前を示せ。」

```
SELECT ENAME
FROM EMP E IN EMP
WHERE SAL >
  (SELECT SAL
   FROM EMP
   WHERE MNO=E.MGR);
```

Q10. 「所属社員数が 10 人以上である部門の部門コードと部門名を示せ。」

```
SELECT DNO,DNAME
FROM DEPT D IN DEPT
WHERE 10 <
  (SELECT COUNT(*)
   FROM EMP
   WHERE DNO=D.DNO);
```

今まで紹介してきた例は、すべて、取り出した domain がすべて 1つの関係  
形式内にある場合であった。しかしながら、例えば、社員名 (ENAME) とその所属  
部門名 (DNAME) が知りた場合では、ENAME は関係形式 EMP から、また、  
DNAME は関係形式 DEPT から取り出す必要がある。このように、取り  
出すべき domain が複数個の関係形式にわたる場合、SEQUEL では、その  
ために用意されている COMPUTE 節を用いることになる。

すなわち、COMPUTE 節で、下位ブロックから渡される値と変数を与え、この変数名を SELECT 節に書くことで、目的が達せられる。

Q 11. 「社員の名前とその所属部門の名前とを示せ。」

```
SELECT  ENAME, Q
FROM    E IN EMP
COMPUTE Q=
        SELECT  DNAME
        FROM    DEPT
        WHERE   DNO=E.DNO;;
```

Q 12. 「すべての部門について、部門コード、部門名、それに所属社員の平均給料を示せ。」

```
SELECT  DNO, DNAME, Q
FROM    D IN DEPT
COMPUTE Q=
        SELECT  AVG(SAL)
        FROM    EMP
        WHERE   DNO=D.DNO;;
```

### 3 SEQUEL システムの内部構造

現在、稼動している SEQUEL プロトタイプ システムは、IBM・VMF370/CMS の下での single user システムであり、その概略の構造は、図 3.1 に示したようになっている。

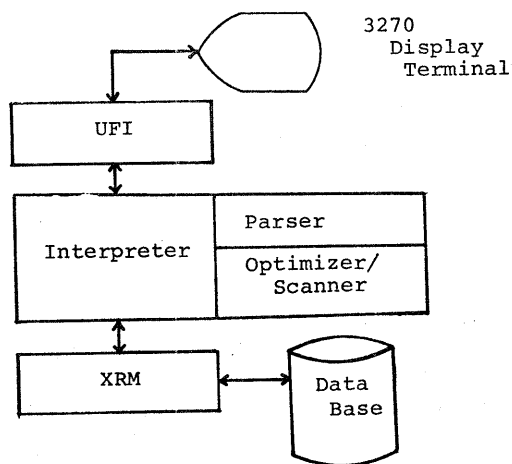


図 3.1  
SEQUEL システム  
の構造

UFI (User Friendly Interface) は、端末からの入力あるいは端末への出力を、管理する interface であり、照会の結果得られた表が端末の画面に表示される場合は、scrolling をつかさどる機能ももっている。

interpreter は、UFI から受けとった入力文を、まず構文解析し、得られた parse tree を基としてデータ・ベースを探索し、結果を UFI に渡す。構文解析には、LALR(k) 型の parser [8] が用いられている。なお、XRM および optimizer/scanner については、次節以降で詳しく述べてゆく。

### 3.1 XRM (EXTENDED RELATIONAL MEMORY) [9]

XRMシステムは、任意の次数の関係形式を格納・検索するデータ・ベースシステムであり、SEQUEL における物理的データベース管理および検索は、図3.1に示したように、すべてこのXRMによって行われる。また、XRMは、さらに2項関係データベースをサポートするRM (Relational Memory) システムの上に組み上げられている。したがって、ここでは、まずRMの紹介を行う。次にXRMがRMの上にどのように組み上げられているのを見ることにする。

RMでは、データベース全体を、entity spaceとrelation spaceとの2つに分割し、ともに4バイトのページ単位で、ディスクへの読み取りを行う。許されるデータ・タイプとしては、1ワードの数値データと可変長の文字列データとがあるが、文字列データはすべて1つのentityとしてentity spaceに格納され、固有の内部コードすなわち1ワードのeid (entity id) が与えられる。




図 3.2 RM entity page format

NL: name length  
DL: data length  
TYPE: entity type  
(1): first 12 bytes of name and data  
(2): continuation of (1)

$eid = (\text{page no}) * c1 + (\text{offset}) / c2$   
c1: no of table entries/page  
c2: length of table entry

一方、relation spaceでは、2項関係が格納され、それらは内部コード rid (relation id) によって識別される。また、これらの2項関係内に現われるデータ項目は、すべて1ワードの数値データもしくは内部コードである。今、ridで識別される2項関係が、 $\{ \langle A_1, B_1 \rangle, \langle A_2, B_2 \rangle, \langle A_2, B_3 \rangle, \langle A_2, B_4 \rangle, \langle A_3, B_5 \rangle \}$  であるとすれば、relation space内での表現は、図3.3のようになる。

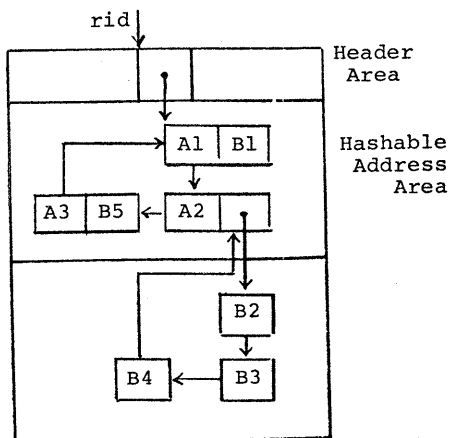


図 3.3 RM relation page format

$A1 < A2 < A3$   
 $B2 < B3 < B4$

$rid = (\text{page no}) * k1 + (\text{offset}) / k2$   
k1: no of header entries/page  
k2: length of header entry

rid が与えられれば、header entry の位置が分かり、pointer をたぐることで、すべての 2 個組が得られるし、また、さらに才 1 domain の値  $A_i$  も与えられれば、 $(rid, A_i)$  を hashing することでより、直接求める 2 個組の位置が得られるようになる。relation page が overflow した場合  $\times$  は、overflow page  $\times$  2 個組が入れられるが、rid でたづねる元 page  $\times$  才 1 domain の値  $\times$  ついで index を持つたの  $\times$ 、高々 2 page 読むだけで、求める 2 個組が得られる。以上述べてきたように、RM  $\times$  ための検索等はすべて内部コード  $\times$  基つて行われる。したがって、検索の時  $\times$ 、文字列データ (外部名) そのものを頻繁  $\times$  使用しない場合は、使用者自身が index をつくり、文字列から内部コード  $\times$  の変換を迅速  $\times$  する必要がある。この index は、文字列  $S$  を hashing して得られる組  $h(S)$  と、 $S$   $\times$  対応する eid とからなる 2 個組  $\langle h(S), eid \rangle$  を要素とする RM  $\times$  2 項関係  $\times$  より実現される。以後、このような 2 項関係を、特に、hash relation と呼ぶことにする。

XRM は、最初  $\times$  述べたように、すべての  $n$  項関係を、RM の 2 項関係  $\times$  によって表現するものであり、RM 同様、処理は内部コード  $\times$  基つて行われる。すなわち、各  $n$  項関係  $\times$  は rid が、また、各  $n$  個組  $\times$  は tid (tuple id) が与えられ、この内部コードを指定する事  $\times$  より、検索が迅速  $\times$  行われるようになる。XRM の関係形式  $\times$  は、大別して、class relation (1 項関係) と regular relation (一般  $\times$   $n$  項関係) との 2 種類がある。

class relation は、可変長の文字列データ (外部名) から内部コード  $\times$  の、あるいはその逆の変換  $\times$  行なうものであり、RM レベル  $\times$  は次の様  $\times$  実現される。

1) hash relation  $C$  が作られる。

2) class relation の要素  $\times$  なる各文字列データ  $S$   $\times$  ついて、

2.1)  $S$  を entity space  $\times$  に登録する。ここで得られる eid が XRM  $\times$  ための tid として使われる。

2.2)  $S$  を hashing して得られる値  $h(S)$  と eid とからなる 2 個組  $\langle h(S), eid \rangle$  を  $C$   $\times$  入れる。

regular relation は、RM の 2 項関係と同じく、1ワードの教値  $\times$  しくは内部コード  $\times$  だけで、データ項目  $\times$  として含む得る。すなわち、XRM  $\times$  ための  $n$  個組  $\times$  は  $n$  ワードから成る文字列  $\times$  として表現される。regular relation の RM レベル  $\times$  の表現は次の様  $\times$  なる。

1) hash relation  $R$  が作られる。

2) regular relation の要素  $\times$  なる各  $n$  個組  $\times$  ついて、

2.1)  $n$  個組  $\times$  を  $n$  ワードから成る文字列  $\times$  として、entity space  $\times$  に登録する。ここで得られる eid が、XRM の tid となる。

2.2)  $n$  個組  $\times$  の primary key の値  $\times$  を  $k$   $\times$  があると、 $k$  を hashing して得られる値  $h(k)$  と eid とから成る 2 個組  $\langle h(k), eid \rangle$   $\times$  を、 $C$   $\times$  に登録する。

$n$  個組  $\times$  を逐次探査  $\times$  しく直接取り出すためには、普通、tid  $\times$  しくは primary key の値  $\times$  を指定  $\times$  する必要がある。ただし、XRM  $\times$  は、任意  $\times$  domain  $\times$  ついで index —  $\times$  これを inversion relation と呼ぶ — を作製  $\times$  する様指定  $\times$  する事ができ、 $\times$  しくより、その domain の値  $\times$  から tid  $\times$  を直接得  $\times$  ることができるよう  $\times$  なる。inversion relation は、指定  $\times$  した domain の値  $\times$  と、対応  $\times$  する  $n$  個組  $\times$  の tid

とを関連づける RM の hash relation で表現される。ただし、inversion relation はあくまでも、システム内部で保守・使用されるものであり、XRM 使用者が直接その中味を取り扱ふことは許されない。

XRM システムにおけるデータ・ベース・カタログは、master relation と呼ばれる、やはり関係形式になっている。master relation は、データ・ベース内の各項目関係に対応した n 個組を要素としており、domain, inversion relation, primary key 等々に関する情報をもっている。なお、master relation における tid が、XRM における対応する項目関係の rid となっている。

### 3.2 Optimizer / Scanner

検索の最適化とは、本来、データベースへのアクセス回数を最小にするということであるが、SQL では、XRM および仮想記憶システム (VMF370 は仮想記憶システムである) の paging を制御することは不可能であるため、その目標を、n 個組を取り出す回数を最小にするという真意置く。言い換えると、index (inversion relation) を極力利用して、逐次探査をする範囲を可能な限り小さくすることである。例えば、"domain-name = value" という条件が与えられる場合、index が利用可能であれば、それの tid の list を得ることを試みる。このような index が利用可能な条件を注目して、最終結果に入り得る n 個組の範囲をせよ。その tid の list を作成するのは Optimizer であり、その tid の list を基にして n 個組を読み込んで check をし、最終結果を作り上げるのは Scanner である。Optimizer / Scanner による処理は、A, B, C の 3 段階に分かれており、以下、順次述べられていく。なお、照会又は一般に、プログラムの不構造をなしており、全体としての処理ロジックは木構造の上から下へと再帰的に行なう。

A) プログラム内の各条件を次の 5 つに分類する。

P1: index の利用により それの解決できる (tid の list が得られる) もの。すなわち、"domain-name = value" または "domain-name IN value-list" の形をしているもの、あるいは上位プログラムを含んでいても、そのプログラムが単純で上と同等とみなせるもの。例えば、DNO の index がある時、  
DNO IN SELECT DNO FROM DEPT WHERE LOC = 'NEWBERG'。

P2: index が存在しないか、あるいは、存在してもそれを利用できないもの。たとえば、DNO > 27。ただし、上位プログラムと、組変数による関連はもたないものであり、したがって、1 回の逐次探査により、解決できるものである。

P3: 上位プログラムと、組変数による関連をもち、上位から 1 つの n 個組が与えられるのは、index により解決できるもの。例えば、EMP の DNO についての index がある時、

```
SELECT NAME FROM D IN DEPT WHERE 10 >
```

```
SELECT COUNT(*) FROM EMP WHERE DNO = D.DNO ;;
```

P4: P3 と同じだが、それ index が存在しないもの。この場合、必要であれば、一時的な index が作製される。

P5: 上位プログラムと、組変数による関連があり、しかも index が存在しても、それを利用する事ができないもの。

A段階が終わって、アロクが P1, P2 のいずれしかない場合は B段階へ進み、そうでない場合は C段階へ進む。

B) この段階では、各条件は P1 か P2 のいずれかであり、P1 から index によって解決可能 (R)、P2 から不可能 (N) の印をつける。一般に、検索条件全体は、AND, OR で結ばれた木構造としているので、更にこの木全体を渡り歩いて、その node の R か N の印をつける。と同時に、条件の list である P\*-list を作ってゆく。(Index Selection Algorithm)




図 3.4  
Index Selection の例

例から分かるように、木構造の根に対応する P\*-list は、index によって、あらかじめ解決することが有効である条件の list となっている。つまり、P\*-list をもとめて、index を利用し各 tid の list (Li) を各 node につけて作成してゆく。このとき、index で完全に解決されたものは R を、最終結果に入り得る n 個組の範囲から除外された場合は S を、また、それ以外の場合、すなわち最終結果の候補となる n 個組が依然としてその n 項関係全体からなっているものは N の印をつける。(List Combining Algorithm)

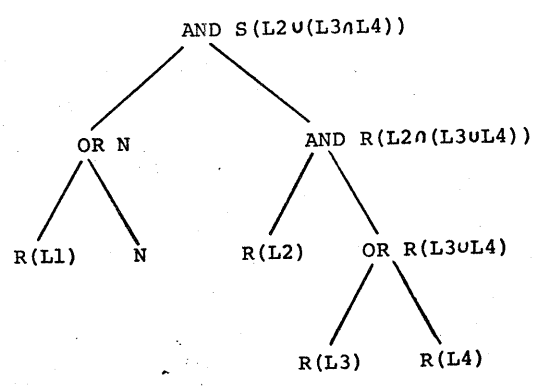


図 3.5  
List Combining の例

Scanner は、この木構造に基づいて n 個組をとり出し最終結果をとりあける。もし、この木構造の根が R であれば、単に tid の list に対応する n 個組をとり出すだけである。S または N であれば、n 個組を 1 個 1 個取り出して、条件を満たすかどうか check する。(Test Tree Algorithm)



c) この段階で処理されるブロックは、少なくとも P3, P4, P5 のうちの1つを含むものであり、上位ブロックと、組変数により関連づけられている。したがって、このブロックは、上位ブロックから渡される  $m$  個組 1個1個に対応して、反復処理を繰り返す必要がある。

そこで、反復処理にかかる手数を出来るだけ減らすために、次の様な前処理を行なっておく。まず Index Selection Algorithm により、P\*-list を作り上げる。ただし、このとき P1, P2, P3, P4 ならば R とし、P5 ならば N とする。次にこの P\*-list の現れる部分の条件に対して、その条件のタプルに応じて次の様な処理を行なう。

P1: List Combining Algorithm により tid の list を作る。

P2: Scanner を用いた逐次探索と条件の check を行ない、P1 と同様の最終的な tid の list を作る。ただし、もしこの P2 ブロックが、自分自身の組変数と関連を持つような下位ブロックを含むならば、Scanner を再帰的に呼び出して、その下位ブロックの処理も行なってしまう。

P3: 何もしない。

P4: 一時的な index を作り、P3 に変換する。

以上の前処理が終わった段階で、Optimizer は、その上位ブロックの処理にかかる。ただし、このとき、このブロックは反復処理が必要であるという事を示しておく。

なお、反復処理の際には、まず P3 に対して List Combining Algorithm により tid の list を作成し、それから Test Tree Algorithm による、最終結果の作成に移る。

## 参考文献

- [1] Codd, E.F., A Relational Model of Data for Large Shared Data Banks, Comm. ACM 13(1970) 377.
- [2] Codd, E.F., Relational Completeness of Data Base Sublanguages, Courant Computer Science Symposia, Vol. 6, Prentice Hall (1971).
- [3] Codd, E.F., Further Normalization of the Data Base Relational Model, Courant Computer Science Symposia, Vol. 6, Prentice Hall (1971).
- [4] Bjorner, D., Codd, E.F., Deckert, K.L. and Traiger, I.L., The Gamma-0 N-ary Relational Data Base Interface Specifications of Objects and Operations, Research Report RJ 1318, IBM Research Laboratory, San Jose (1973).
- [5] Boyce, R.F., Chamberlin, D.D., King, W.F. and Hammer, M.M., Specifying Queries as Relational Expressions, Proc. of ACM SIGPLAN/SIGIR (1973).
- [6] Codd, E.F., A Data Base Sublanguage Founded on the Relational Calculus, Proc. of ACM SIGFIDET Workshop (1971).
- [7] Chamberlin, D.D. and Boyce, R.F., SEQUEL: A Structured English Query Language, Proc. of ACM SIGFIDET Workshop (1974).
- [8] Lalonde, W.R., Lee, E.S. and Horning, J.J., An LALR(k) Parser Generator, Proc. of IFIP Congress 1971, North Holland (1972) 513.
- [9] Lorie, R.A., XRM--An Extended (N-ary) Relational Memory, G320-2096, IBM Scientific Center, Cambridge (1974).

