

(1991. 3. 11)

## 拡張可能DBMS:COMMONの格納構造と基本演算について

宝珍 輝尚

NTT情報通信処理研究所

拡張可能DBMS:COMMONで採用するデータを表現するグラフ(データグラフ)のための基本演算を提案し、基本演算の実現方法について述べる。まず、データグラフを多種の意味的なデータモデル実現のプラットフォームとしたCOMMONの概要を述べる。次に、データグラフのための基本演算について述べる。ここでは、従来の巡航的な基本演算を示し、手続き的に使用せずにデータグラフを操作可能な基本演算(集合、複写、部分グラフ化、統合、順序化、集約化および再帰に関する演算)を提案する。そして、COMMONで選択可能とする3種の格納構造に基づいた基本演算の実現方法について述べる。

## Storage Structure and Primitive Operations for Extensible DBMS:COMMON

Teruhisa HOUCHIN

NTT Communications and Information Processing Laboratories

1-2356 Take, Yokosuka-Shi, Kanagawa 238-03, Japan

Primitive operations and their implementations for data representing graphs(data graphs) in the extensible DBMS:COMMON are suggested. First, the COMMON's features are described. COMMON works on data graphs according to support several semantic data models. Next, operations for data graphs are described. They are divided into 2 groups: procedural and non-procedural ones. Set, copy, subgraph, unite, ordering, aggregating, and recursive operations are suggested as non-procedural ones. And next, implementations of non-procedural ones are studied on COMMON's selective storage structures.

## 1. はじめに

DBMSの拡張性を高める研究が盛んに行われている<sup>(1-11)</sup>。この拡張可能DBMSの研究アプローチは大別してフル機能DBMSアプローチとDBMS generatorアプローチに分けられる。フル機能DBMSアプローチは、完全な機能を持つDBMSに対してDBMS応用分野で要求される機能追加を容易とするアプローチであり<sup>(2,3)</sup>、DBMS generatorアプローチは、様々な部品を組み合わせてDBMS応用分野に応じたDBMSを構築するというアプローチである<sup>(4-11)</sup>。後者のアプローチには多種の意味的なデータモデル実現の研究もある<sup>(7)</sup>。筆者は後者のアプローチを採り、多種の意味的なデータモデル実現等を目指し、COMMONと名付けたDBMS generatorを試作中である。COMMONでは、多種の意味的なデータモデル実現のために論理的な格納構造としてグラフ(データグラフ)を採用し、グラフの物理的な格納構造の提案を行っている<sup>(11)</sup>。この格納構造はグラフの枝または点に着目したものであり、COMMONではこれらの格納構造と従来の格納構造を選択可能とする。

ここで、COMMONを使用して構築するDBMSでも関係型DBMSのような高水準なデータベース操作言語サポートの要求が考えられるが、このためには関係代数のような基本演算が必要である。

そこで、本稿ではデータグラフのための巡航的な基本演算の明確化、手続き的に使用せずにデータグラフを操作可能な基本演算の提案を行い、さらに、COMMONで選択可能とする3種の格納構造に基づく基本演算の実現方法について述べる。

以下、2.でCOMMONの概要について述べ、3.でデータのグラフ表現と格納構造について述べる。次に、4.でデータグラフに対する基本演算について述べ、5.で基本演算の実現方法について述べる。最後に、6.で関連する研究との比較を行う。

## 2. 拡張可能DBMS: COMMON

### 2.1 COMMONの概要

#### 2.1.1 背景

COMMONでも他の拡張可能DBMS<sup>(2-8)</sup>と同様、

様々なDBMS応用分野に対するDBMSの迅速な構築を目指している。このために、①DBI(DBインプリメンタ)の負荷軽減、②多種の意味的なデータモデル実現可能化を図ることが重要であると考えている。

DBIはDBMSという大規模なソフトウェアの設計・構築・維持管理を行わなければならない、その負荷が膨大となる。この負荷は、DBMS generatorではフル機能DBMSを拡張した拡張可能DBMSよりも大きなものとなる。従って、実用的なDBMS generatorにはDBIのための様々な負荷軽減策が必要である。現在、COMMONではこの負荷軽減のために、DBMS処理データのDB化<sup>(9)</sup>、柔軟なモジュール・インタフェース<sup>(9)</sup>を導入している。これらの概要を2.1.2で述べる。

多種の意味的なデータモデルの実現を目指す目的は、DBMS応用分野で必要とされる独自のデータモデルを容易に実現するためである。独自のデータモデルとは、地図分野において線分と地点との接続関係をプリミティブなデータモデルの構成要素としている<sup>(12)</sup>といったものである。このために、現在COMMONは、多種の意味的なデータモデルのプラットフォームとしてのデータのグラフ表現、選択可能な格納構造を導入している。これらについては3.で詳しく述べる。

#### 2.1.2 特徴

##### (1) DBMS処理データのDB化<sup>(9)</sup>

COMMONは、DBMSの処理に使用するデータ(DBMS処理データ)のデータベース化を実現するDBMSコアモジュール群とユーティリティから構成される(図1)。DBMS処理データとは、例えば、データベース操作言語の解析後に作成される構文木等のデータである。DBMSコアモジュールでは、これらのDBMS処理データの管理及び処理を行い、DBMS処理データのDB化を実現する。

COMMONを用いたDBMSの構築例を図1に示す。図1では、DBMS制御、構文解析、最適化、プラン実行というDBMS実現モジュールをDBIが作成している。ここで、DBMS実現モジュールとは、DBMSコアモジュール群を用いてDBMSの処理を行うモジュールの総称である。

##### (2) 柔軟なモジュール・インタフェース<sup>(9,10)</sup>

COMMONでは、DBMSを構成するモジュール間のインタフェースデータの授受を支援するインタフェースデータ管理部 (DBI) を導入している。これにより、インタフェースデータ中の必要なデータ項目のみが選択的に操作でき、インタフェースデータを論理的に操作できる。

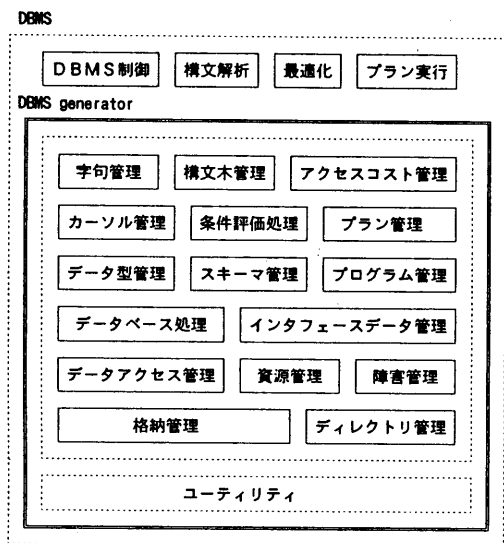


図1 DBMS構築システムを用いたDBMSの構成例

### 3. データのグラフ表現と格納構造

#### 3.1 データグラフ

COMMONでは、多様な意味的なデータモデルのプラットフォームとして、データを表現するグラフ (データグラフ) を採用する。これは、グラフがデータ構造の中で最も一般的であり、さらに、様々なタイプ構成子およびタイプ間の関連を用いてデータの持つ意味を構造的に表現する意味的なデータモデル<sup>(12)</sup>の表現に適するためである。

##### 3.1.1 定義

まず、グラフの構成要素の定義を行う前に、データの一意識別子とデータ型の定義を行う。

[定義1] (一意識別子) 関係  $R_{ID}$  が全順序であるような集合  $D_{ID}$  を考え、その要素  $d_{ID}$  を一意識別子といい、 $D_{ID}$  を一意識別子の定義域という。

[定義2] (データ型) データ値を格納するデータフォーマットとこのデータフォーマット上のデータ値

を処理する手続きの集合とデータに対する制約の集合をデータ型といい、データ型に付与された名前をデータ型名という。

[定義3] (データ) 組  $(DTN, dv)$  をデータという。ここで、 $DTN$  はデータ型名、 $dv$  は  $DTN$  の示すデータ型のフォーマット上に表現可能なデータである。

[定義4] (値の定義域)  $n (n \geq 1)$  個のデータ型  $DT_i$  で表現可能な値の集合  $V_i$  の和集合  $V (= V_1 \cup \dots \cup V_n)$  を値の定義域といい、その名前を定義域名という。

[定義5] (点, 枝) 3つ組  $(d_{ID}, DMN, d)$  を点といい、点を要素とする集合を点集合という。5つ組  $(d_{ID}, DMN, d, v_i, v_t)$  を枝といい、枝を要素とする集合を枝集合という。ここで、 $d_{ID}$  は一意識別子、 $DMN$  は定義域名、 $d$  はデータ、 $v_i$  は枝の始点、 $v_t$  は枝の終点。

[定義6] (データグラフ) 点集合  $V$  と枝集合  $E$  からなる順序組  $(V, E)$  が連結グラフである場合、グラフ  $g (V, E)$  をデータ表現グラフという。また、データ表現グラフを成分にもつ非連結グラフ  $G (V, \Sigma)$  をデータ群グラフという。データ表現グラフとデータ群グラフを総称してデータグラフという。

[定義7] (集合属性, 単属性) データ表現グラフ中に同一属性名の要素が2以上存在するとき、この属性を集合属性という。また、集合属性でない属性を単属性と区別して単属性と呼ぶ。

データ表現グラフの定義と実体の例を図2に示す。

図2 (b) の属性名  $C$  の点は複数であるので属性  $C$  は集合属性である。

本稿で使用する表記を表1にまとめて示す。




図2 データ表現グラフの例

##### 3.1.2 等価性

###### (1) 絶対等価性

[定義8] (絶対包含性) データグラフ  $P$  と  $Q$  において、 $P$  の要素の一意識別子の集合が  $Q$  の要素の一意識別子の集合を含むとき、 $Q$  は  $P$  を絶対包含するといいい、 $P \subseteq_1 Q$  と表記する。

〔定義9〕(絶対等価性) データグラフPとQにおいて $P \subseteq_I Q$ かつ $Q \subseteq_I P$ であるとき、2つのデータグラフP、Qは値等価であるといい、 $P \# Q$ と表記する。

(2) 全等価性

〔定義10〕(全包含性) グラフとしてデータグラフPがQのサブグラフであり対応する要素が値等価のとき、QはPを全包含するといひ、 $P \subseteq_T Q$ と表記する。

〔定義11〕(全等価性) データグラフPとQがグラフとして枝の向きを含めて同形であり、対応する要素が値等価のとき、PとQは全等価であるといひ、 $P \equiv_T Q$ と表記する。

表1 表記

表記	意味
$v[P]$	データグラフP中の点集合
$e[P]$	データグラフP中の枝集合
$z[P:C]$	データグラフPの属性名Cの示す要素
$id[w]$	要素(点または枝)wの一意識別子
$k[w]$	要素(点または枝)wの持つ値
$i[e]$	枝eの始点
$t[e]$	枝eの終点
$c[v]$	点vの接続枝(点vを始点または終点を持つ枝の集合)
$c[V]$	点の集合Vに属する点を始点または終点を持つ枝の集合
$g \in G$	データ表現グラフgはデータ群グラフGの成分
$g \in P$	データグラフPがデータ群グラフのとき $g \in P$ 、データグラフPがデータ表現グラフのとき $g = P$

3. 2 選択可能な格納構造

3. 2. 1 3種の格納構造

多種の意味的なデータモデル実現の目的は、様々なDBMS応用分野にCOMMONを適用するためである。ここで、DBMSの意識する格納構造はDBMSの性能を決定する大きな要因であるが、該格納構造は固定的であり、DBMSの適用分野に最適であるとは限らない。COMMONでは、条件式評価性能が条件式中の属性のデータ配置上の位置に依存する(位置依存)という特性に着目し、位置依存する格納構造と位置独立な格納構造<sup>(11)</sup>を選択可能とする。これにより、DBIの負荷微増で格納構造の柔軟化を図る。

意味的なデータモデルを実現したDBMSの格納構造<sup>(20, 22)</sup>は位置依存する格納構造であり、操作の起点

となる(グラフの)ソースノードを中心としたデータ構造である。位置独立な格納構造はグラフの連結性に着目したデータ構造であり、連結なデータ表現グラフを単位とし、該グラフの各要素を指すノードを設けて該グラフを管理するものである。

(1) ソースノード中心のデータ構造

ソースノード中心のデータ構造では、点に接続する枝を該点で管理する。データ検索時は、ソースノードから該ノードに接続している要素を順次検索してゆくことになる。この概要を図3(a)に示す。属性Bの点の値(b)は属性Aの点(ソースノード)から枝Xを経由し、該点に到達して初めて得られる。

(2) 点中心のデータ構造

点中心のデータ構造の構成要素は top-n, 点実体, 枝実体, ポインタリストである。top-nは 点の定義数, 点ポインタエントリを格納する。i番目の点ポインタエントリは点の定義番号iの点実体の数と点実体へのポインタを格納する。ただし、点実体数が2以上の場合はポインタリストを指し、ポインタリストが各点実体を指す。点実体と枝実体は従来のデータ構造と同じデータ構造で関係付ける。図2のグラフの本データ構造での表現を図3(b)に示す。本データ構造は、従来のグラフのデータ構造に各点への直接アクセスを可能とする top-nを付加したものと見える。

(3) 枝中心のデータ構造

枝中心のデータ構造の構成要素は、top-e, 枝実体, 点実体, ポインタリストである。top-eは 枝の定義数, 枝ポインタエントリ, 孤立点の数, 孤立点へのポインタリストへのポインタを格納する。枝ポインタエントリは(2)の点ポインタエントリと同様である。枝実体は、枝の値、始点と終点へのポインタを格納する。点実体は点の値のみを格納する。図2のグラフの本データ構造での表現を図3(c)に示す。

点, 枝中心のデータ構造では、定義要素数を既知と仮定した。本仮定は、DBMSの意識する格納構造として本データ構造を使用する場合には常に満足される。

3. 2. 3 3格納構造の特性

3格納構造の長所, 短所<sup>(11)</sup>を概説する。

(1) ソースノード中心のデータ構造

本データ構造は、枝中心のデータ構造と比較して、

巡航検索を検索手段とする場合に有効である。

(2) 点中心のデータ構造

点中心のデータ構造は、枝中心のデータ構造と従来のデータ構造の利点を合わせ持つので、条件検索のみでなく巡航検索をも必要とする場合に有効である。

しかし、本格納構造は(1)、(3)と比較して格納効率ならびにデータ更新性能は良くない。また、本データ構造の特徴である第一要素(top-n)は、要素の定義数に比べデータ実体数が少なくなると格納効率が劣化する。この問題は現在検討中である。

(3) 枝中心のデータ構造

本データ構造は、条件式評価性能が位置依存せず、定義上の要素数により条件式評価性能を見積ることができる。また、属性のデータ表現グラフ上の位置によっては(1)よりも高速である。

格納効率は(1)と同等である。ただし、top-eについてはtop-nと同様の問題がある。

4. グラフデータのための基本演算

ここでは、3.1で述べたデータグラフを非手続的に操作可能な演算を提案する。これに先立ち、データグラフに対する既存の巡航的な演算を明確化する。

4.1 巡航的な基本演算

(1) 現在指示子

[定義12] (現在指示子) データグラフ中の着目している要素を示す指示子を現在指示子という。

(2) 点の移動


[定義13] (点の移動) 点の移動とは、ある属性の点集合VとV中の一点 $v_0$ とV中の要素の値の集合を半順序集合とする関係Rが与えられたときに、以下の規則に従って点集合Vから点の一つを選ぶ演算( $m_v(v_0, V, R) = v_1 \in \{v \mid v \in V \wedge \neg v \# v_0\}$ )である。

[規則1] 関係Rの順序関係に従って $v_0$ の次の点を選択する。関係Rに関して比較不能かまたは関係Rが与えられないときは規則2に従う。


[規則2] 一意識別子の関係 $R_{ID}$ の順序関係に従って $v_0$ の次の点を選択する。

(3) 枝にそった移動


[定義14] (枝の前後への移動) 枝の前(後)への移動とは、属性、値、始点(終点)を一にする枝の集合



(a) ソースノード中心のデータ構造



(b) 点中心のデータ構造



(c) 枝中心のデータ構造

図3 選択可能とするデータ構造

EとEの終点(始点)の一つ $v_0$ と終点(始点)の値の集合を半順序集合とする関係Rが与えられたときに、終点(始点)の集合に上記の規則1、2を適用して終点(始点)の一つを選ぶ演算である。枝の前への移動は $m_{of}(v_0, E, R) (= v_1 \in \{t[e] \mid e \in E \wedge \neg t[e] \# v_0\})$ 、枝の後ろへの移動は $m_{ob}(v_1, E) (= v_1 \in \{i[e] \mid e \in E \wedge \neg i[e] \# v_1\})$ と表記する。

(4) 付加, 除去, 複写

ここでは、更新系の演算について述べる。

[定義15] (付加) データグラフ $P(V, E)$ にグラフ $Q(V', E')$ を付加するとは、点集合 $V \cup V'$ および枝集合 $E \cup E'$ を持つグラフ $(V + V', E + E')$ を作ることである。これを $P + Q$ で表す。従って、 $P + Q = (V + V', E + E')$ 。

[定義16] (除去) データグラフ $P(V, E)$ からグラフ $Q(V', E')$ を除去するとは、VからV'の点を除去し、除去される点に接続するPの全ての枝とE'の和をEから除去することである。これを、 $P - Q$ で表す。従って、 $P - Q = (V - V', E - (e[V_r] \cup E'))$ 。ただし、

$V_r = \{v \mid v \# v' \wedge v \in V \wedge v' \in V'\}, V' \subseteq V, E' \subseteq E.$

#### 4. 2 非手続的な基本演算

ここでは、非手続的なデータグラフ演算を提案する。提案する演算は、集合演算、複写演算、部分グラフ化演算、統合演算、順序化、集約化および再帰に関する演算である。以下では特に断わらない限り、点または枝を要素と表記する。

##### 4. 2. 1 集合演算

データグラフを構成する要素は一意識別子をもつので一意識別子を考慮した集合演算を定義する。

[定義 1 7] (共通部分, 合併, 差) データグラフ  $P_1(V_1, E_1)$  とデータグラフ  $P_2(V_2, E_2)$  の共通部分  $P = P_1 \cap P_2$ , 合併  $P = P_1 \cup P_2$ , 差  $P = P_1 - P_2$  とは、それぞれ、点集合  $V_1 \cap V_2$ , 枝集合  $E_1 \cap E_2$  を持つグラフ, 点集合  $V_1 \cup V_2$ , 枝集合  $E_1 \cup E_2$  を持つグラフ,  $V_2$  に属さない  $V_1$  の点集合と  $E_2$  に属さない  $E_1$  の枝集合を持つグラフである。

一意識別子を考慮せず要素の値のみに着目した集合演算は、値を一にする要素を同一要素とする必要があり、以降で述べる集合統合によって実現できる。

##### 4. 2. 2 複写演算

さらに、複写演算を定義する。

[定義 1 8] (複写) データグラフ  $P$  の複写 copy  $P$  は、データグラフ  $P$  と全等価であり絶対等価でないデータグラフである。

##### 4. 2. 3 部分グラフ化演算

データグラフの部分グラフを取り出す演算として射影と制約を定義する。

[定義 1 9] (射影) データグラフ  $P$  の点または枝の属性  $C_1, \dots, C_n$  への射影  $P[C_1, \dots, C_n]$  は、指定された属性の要素のみからなるグラフである。

[定義 2 0] (制約) データグラフ  $P$  の定義域が等価な 2 つの属性  $C_p$  と  $C_q$  の間の  $\theta$  制約  $P[C_p \theta C_q]$  は、 $C_p$  と  $C_q$  の少なくとも一組の要素の値が  $\theta$  関係を満たすデータ表現グラフを成分とするグラフである。

[例 1] 図 4 (a) の定義に従った図 4 (b) のようなデータグラフ  $P$  に対して、射影を行った結果を図 4 (c) に、制約を行った結果を図 4 (d) に示す。

##### 4. 2. 4 統合演算

データグラフ間の統合に関する演算として、直統合、

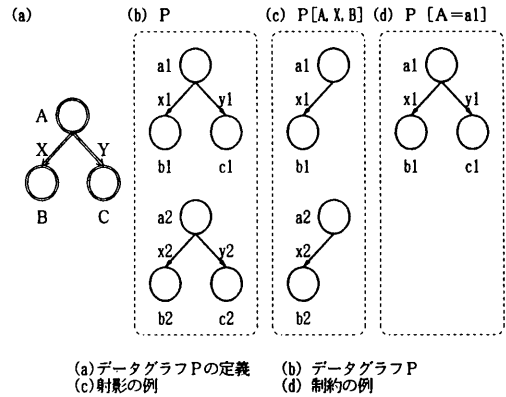


図 4 部分グラフ化の例

制約統合, 関係統合, 集合統合を定義する。

(1) 直統合 直統合は要素を無条件に統合する。

[定義 2 1] (直統合) データグラフ  $P$  の属性  $C_p$  へのデータグラフ  $Q$  の属性  $C_q$  の直統合  $P[C_p \langle (C_q) Q]$  は、属性  $C_q$  の要素を属性  $C_p$  の要素としたグラフである。

(2) 制約統合 制約統合は、要素の値の  $\theta$  関係 ( $\theta$  は  $=, \neq, <, >, \leq, \geq$ ) を使用して要素を統合する。

[定義 2 2] (制約統合) データグラフ  $P$  とその属性  $C_p, C_{pc}$ , データグラフ  $Q$  とその属性  $C_q, C_{qc}$  があるとき、 $P$  の属性  $C_p$  への  $Q$  の属性  $C_q$  の  $C_{pc} \theta C_{qc}$  に基づく制約統合  $P[C_p \langle (C_q (C_{pc} \theta C_{qc})) Q]$  は、属性  $C_{qc}$  の要素の値が属性  $C_{pc}$  の要素の値と  $\theta$  関係のときに限り  $C_q$  の要素を  $C_p$  の要素としたグラフである。

(3) 関係統合 関係統合は、要素の値の  $\theta$  関係 ( $\theta$  は  $=, \neq, <, >, \leq, \geq$ ) を使用し、 $\theta$  関係を満たす要素のみを結果とする。

[定義 2 3] (関係統合) データグラフ  $P$  とその属性  $C_p, C_{pc}$ , データグラフ  $Q$  とその属性  $C_q, C_{qc}$  があるとき、 $P$  の属性  $C_p$  への  $Q$  の属性  $C_q$  の  $C_{pc} \theta C_{qc}$  に基づく関係統合  $P[C_p \langle (C_q (C_{pc} \theta C_{qc})) Q]$  は、属性  $C_{qc}$  の要素の値が属性  $C_{pc}$  の要素の値と  $\theta$  関係のときに限り  $C_q$  の要素を  $C_p$  の要素とし、 $\theta$  関係にないデータグラフの要素を含まないグラフである。

(4) 集合統合 集合統合は値の集合に集合演算 ( $\omega$  は共通部分 ( $\cap$ ), 合併 ( $\cup$ ), 差 ( $-$ )) を行って統合する。

[定義 2 4] (集合統合) データグラフ  $P$  とその属性  $C_p, C_{pc}$ , データグラフ  $Q$  とその属性  $C_q, C_{qc}$  があるとき、 $P$  の属性  $C_p$  への  $Q$  の属性  $C_q$  の  $C_{pc} \omega C_{qc}$  に基づく集合統合  $P[C_p \langle (C_q (C_{pc} \omega C_{qc})) Q]$  は、属

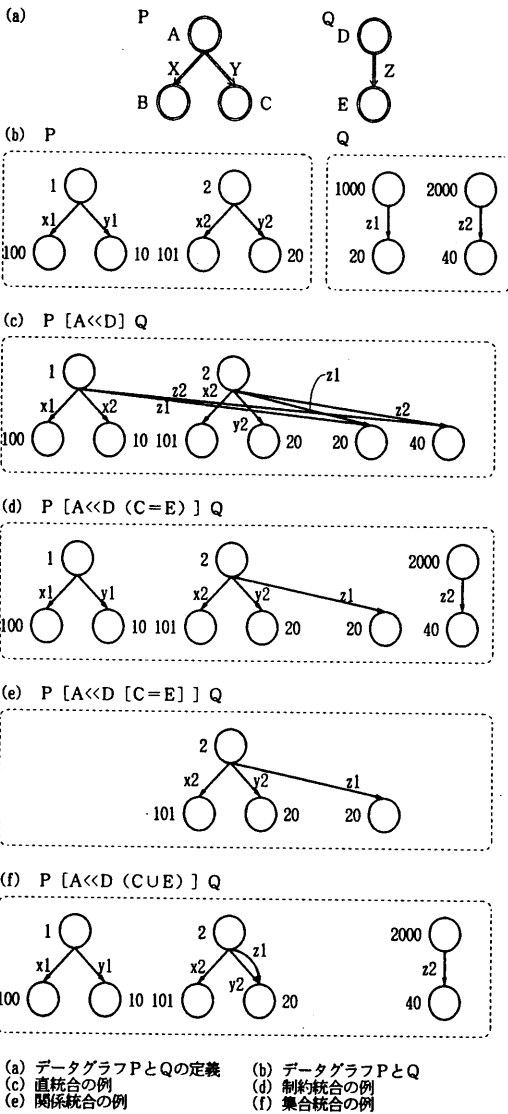


図5 統合の例

性  $C_{0c}$  の要素の値の集合と属性  $C_{pc}$  の要素の値の集合に集合演算  $\omega$  を施した結果の値の集合をもつように  $C_0$  の要素を  $C_p$  の要素としたグラフである。

【例2】 図5(a)のような定義で図5(b)に示すデータグラフPとQに対して、直統合、制約統合、関係統合、集合統合を行った例を各々図5(c)~(f)に示す。

#### 4. 2. 5 順序化に関する演算

データベースから要素の値で順序付けて検索結果を得ることは利用者にとって不可欠である。このために、データベースへのデータ格納時に順序付けておく

ことも可能であるが、リレーショナル型のDBMSのように動的に順序化する演算も必要である。

【定義25】 (順序化) データグラフPの属性  $C_1, \dots, C_k$  の各属性の順序組  $(C_1, \dots, C_k)$  において関係Rが半順序であるとき、属性  $C_1, \dots, C_k$  における関係Rに関する順序化  $P[\text{order}(C_1, \dots, C_k), R]$  とは、組  $(a_{11}, \dots, a_{1k})$  を要素とする集合を関係Rに関して半順序集合とすることである。ただし、 $a_{1i} = k[z(g_i; C_{1i})]$ ,  $g_i \in P$  である。

#### 4. 2. 6 集約化に関する演算

データを集約したいという要求もデータベース利用者にはある。すなわち、データの総数、データの値の合計、平均、最大、最小を求めることである。ここでは、集約化ならびに集約演算を定義する。

##### (1) 集約化

【定義26】 (集約化) データグラフPの属性  $C_1, \dots, C_k$  に関する集約化とは、各属性  $C_i$  の要素  $c_i$  からなる順序組  $(c_1, \dots, c_k)$  が同一である場合に、同一とみなす属性の要素を統合することである。

集約化は、 $\cup$  集合統合を用いて表現できる。例えば、 $P[C_1 \langle \langle C_1, \dots, C_k \rangle \langle C_k \rangle ((C_1, \dots, C_k) \cup (C_1, \dots, C_k)) \rangle] P$  や、 $P[C_0 \langle \langle C_0, C_1 \rangle \langle C_1, \dots, C_k \rangle \langle C_k \rangle ((C_1, \dots, C_k) \cup (C_1, \dots, C_k)) \rangle] P$  である。ただし、 $(C_1, \dots, C_k)$  は順序組を表す。

集約化によって同一とみなされる1以上のデータ表現グラフは1データ表現グラフとなる。さらに、(2)で述べる集約演算を用いて集約化されなかった要素の集約値を得ることができる。

##### (2) 集約演算

【定義27】 (点の縮約) 点集合Vの要素を単一の点とすることを点の縮約という。縮約される前の点を始終点とする枝は、点の縮約によって縮約後の点を始終点とする枝に変更される。

【定義28】 (枝の縮約) 始終点を一にする枝集合Eの要素を一つの枝とすることを枝の縮約という。

【定義29】 (縮約の表記と値) 要素集合Wの縮約を  $\text{comp}W$  と表記し、Wの全要素が同一値dであるとき、 $\text{comp}W$  の値をdとし、それ以外はNULL(値なし)とする。

点の縮約と枝の縮約の順序によって縮約結果が異なるので注意が必要である。

【定義30】 (カウント, 合計, 平均, 最大, 最小)

値が可算な要素集合Wに対して、要素集合Wの要素を、要素の数を値にもつ要素 $w_{count}$ に縮約する演算、Wの要素の値の総和を値にもつ要素 $w_{sum}$ に縮約する演算、Wの要素の値の平均値を値にもつ要素 $w_{avg}$ に縮約する演算、Wの要素の値の最大値を値にもつ要素 $w_{max}$ に縮約する演算、Wの要素の値の最小値を値にもつ要素 $w_{min}$ に縮約する演算を、それぞれカウント(count W)、合計(sum W)、平均(avg W)、最大(max W)、最小(min W)という。

[定義3 1] (集約演算) データグラフPの属性Cについての集約演算 $P[go(C)]$ は、Pの成分であるデータ表現グラフ毎に属性Cの表す要素集合に集約演算goを施してできる以下のグラフである。ここで、集約演算goとは、count, sum, avg, max, min, compである。

(a) Cが点属性の場合、 $P[go(C)] = (\{w_i\}, \{\})$ 。ここで、 $w_i = goW_i$ ,  $W_i = \{z[g_i : C] \mid g_i \in P\}$ 。


(b) Cが枝属性の場合、 $P[go(C)] = (\{\}, \{w_i\})$ 。ここで、 $w_i = goW_i$ ,  $W_i = \{z[g_i : C] \mid g_i \in P\}$ 。

[例3] 集約化の例を図6に示す。データグラフPを(A, X, B, Y, C)に着目して集約化し(図6(c))、さら


(a)




(b) P



(c)  $R = P[A \ll A(AUA)] P$



(d)  $R[A, countB, compX, countC, compY]$



(a) データグラフPの定義 (b) データグラフP  
(c) 集約化の例 (d) 集約演算の例

図6 集約化の例

に図6(d)では属性B, X, C, Yの集約値を求めている。

#### 4. 2. 7 再帰に関する演算

データベース中のデータに対して演算を再帰的に行ってデータを検索したいということもしばしば起こる。ここでは、閉包、再帰について定義する。

[定義3 2] (閉包) データグラフ演算fがデータグラフPにおけるn項演算であり、 $p_i \in P$ に対して $f(p_1, \dots, p_n) \in P$ が成立するとき、データグラフPはfのもとで閉じているという。

[定義3 3] (再帰) あるデータグラフ演算 $f(P_R, P_1, \dots, P_n)$ を再帰的に行う $f^*(P_R, P_1, \dots, P_n)$ とは、データグラフ $\bigcup_{i=1}^{\infty} Q_i$ を作ることである。ここで、

$$Q_i = \begin{cases} f(P_R, P_1, \dots, P_n) & (i=1), \\ f(Q_{i-1}, P_1, \dots, P_n) & (i \geq 2). \end{cases}$$

このとき、 $P_R$ を被作用データグラフ、 $P_1, \dots, P_n$ を作用データグラフと呼ぶ。

#### 4. 基本演算の実現方法

ここでは、3種の格納構造に基づく射影、制約、統合演算の実現方法について述べる。再帰については現在検討中であり、その他の演算は容易に実現できる。

実現方法の検討にあたり、関係DBのOPEN処理を想定した。この結果、表2に示す4種の処理で実現できることが分かった。表2の各処理(処理1~処理4)の概要を各々図7~図10に示した。点中心の格納構造と枝中心の格納構造は処理の流れは同じである。また、統合は、関係度数の結合と同じ処理で実現できる。従って、格納構造に依存するのは統合処理中の部分グラフ化演算(射影、制約)の処理である。

表2 基本演算の実現方法

基本演算	ノード中心	点/枝中心
射影	処理1	処理2
制約	処理1	処理3
統合	処理4	処理4

#### 6. 関連する研究

##### (1) データのグラフ表現

データを関連というノードを使用せずにグラフで表現するモデルにはSBDM<sup>(18)</sup>、関数型データモデル<sup>(19,20)</sup>、SDM<sup>(21)</sup>、DBGraph<sup>(23)</sup>等がある。



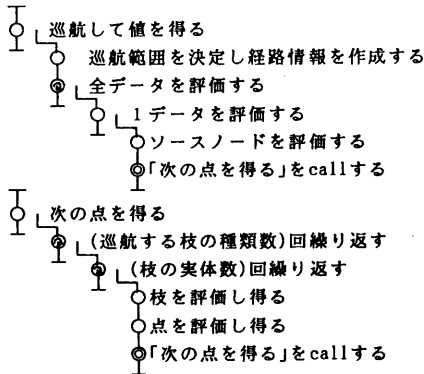


図7 処理1の概要




図8 処理2の概要




図9 処理3の概要




図10 処理4の概要

SBDMでは、二項関連の順方向、逆方向のラベル付けによってデータ間の意味を表現する。また、二項関連が集合の意識を持つ。すなわち、二項関連の端点の値が一意か順序付けするかで二項関連は4分類され、集合の定義および操作を可能とする。本稿のデータグラフではこのような特徴はない。本データグラフではデータをグラフとして表現するのみにとどめ、種々の意味的なデータモデルの特徴をこのデータグラフに追加する形態で実現することを目指している。

関数型データモデル、SDMで表現されたスキーマ、

データ実体もグラフとなる。関数型データモデルではスキーマが一つのグラフで表現される。すなわち、問い合わせに出現するエンティティはあらかじめエンティティ間の関係(関数)が定義されていると考えている。従って、非連結な2グラフをスキーマとするデータを一問い合わせで処理することはない<sup>(20)</sup>。データグラフでは、データ群グラフを導入することで非連結なスキーマの表現を考慮している。

DBGraph<sup>(23)</sup>では、エンティティを表現する点とデータ値を表現する点で構成される2部グラフによりデータを表現する。DBGraphでは同種の点同志を結ぶ枝は考慮されていない。また、点に接続する枝は枝の終点を表現するのみであり、データ構造としては本質的に従来のソースノード中心のデータ構造である。

## (2) 基本演算

データを表現するグラフに対する従来からの基本的な演算は、グラフ中の経路を巡航する<sup>(24)</sup>かまたは巡航経路を指定する<sup>(25)</sup>ものである。前者には利用者が検索経路を指定して手続的に検索しなければならないという欠点がある。後者には操作対象のデータはすべて関連付けられているという前提があり、非連結なデータを表現するグラフを簡単に操作できないという欠点がある。本稿で提案した演算を使用すれば、非手続的な検索、非連結な操作対象の操作が可能である。

意味的なデータモデルであるSDMに基づくDBMS<sup>(22)</sup>やオブジェクト指向データモデルの問い合わせ言語<sup>(16,17)</sup>では関係モデルの結合と同様な演算の提案があるが、これらは関係モデルの結合を単に流用している程度である。これに対し提案した統合演算はデータのグラフ化を基に導いた一般的な演算である。

## 7. おわりに

本稿では、拡張可能DBMS:COMMONで採用するデータを表現するグラフのための基本演算の提案と基本演算の実現方法について述べた。

まず、拡張可能DBMS:COMMONの概要について述べた。COMMONは、DBIの負荷軽減と多種のデータモデル実現を目標としたDBMSgeneratorである。COMMONでは、データを表現するグラフ(データグラフ)を多種の意味的なデータモデル実現の

プラットフォームとし、データグラフのための3種の格納構造を選択可能としている。

次に、データグラフのための基本演算について述べた。従来の巡航的な基本演算を示し、手続的に使用せずにデータグラフを操作可能な基本演算を提案した。これは、集合、複写、部分グラフ化、統合、順序化、集約化および再帰に関する演算である。

さらに、COMMONで選択可能とする3種の格納構造に基づいて基本演算の実現方法を示した。部分グラフ化演算処理は格納構造に依存する。

最後に、データグラフ、基本演算について関連する研究と比較した。データグラフは、単にデータをグラフで表現するもので、多種の意味的なデータモデルのプラットフォームに適した表現である。また、提案した非手続的な演算はデータのグラフ化に基づく一般的な演算である。

今後は、点、枝に着目した格納構造の格納効率向上の検討、データグラフの表現力評価、柔軟な最適化方式の検討、データベース言語処理の一貫性の検討、COMMONの拡張性評価が課題である。

謝辞 本研究を行うにあたり、日頃から議論して頂く田中豪主幹員、田中一敏主幹員をはじめとするNTT情報通信処理研究所の皆様へ感謝致します。

## 文 献

- (1) D. Batory and M. Mannino: "Panel on Extensible Database Systems", Proc. of ACM SIGMOD'86, pp.187-190, 1986.
- (2) M. Stonebraker, L. A. Rowe and M. Hirohama: "The implementation of POSTGRES", IEEE trans. of knowledge and data eng., Vol.2, No.1, pp.125-142, 1990.
- (3) L. M. Haas et al: "Starburst mid-flight: As the dust clears", IEEE trans. of knowledge and data eng., Vol.2, No.1, pp.125-142, 1990.
- (4) D. S. Batory et al: "Implementation concepts for an extensible data model and data language", ACM Trans. Database Sys., Vol.13, No.3, pp.231-262, 1988.
- (5) M. J. Carey et al: "Object and File Management in the EXODUS extensible database system", Proc. of 12th VLDB, pp.91-100, 1986.
- (6) M. J. Carey et al: "A Data Model and Query Language for EXODUS", Proc. of ACM SIGMOD '88, pp.413-423, 1988.
- (7) S. Hong and F. Maryanski: "Using a meta model to represent object-oriented data models", Proc. of 6th Intl. Conf. on DATA Engineering, pp.11-19, 1990.
- (8) 古瀬 他: "拡張可能DBMS MODUSの設計と実現技術", Proc. of ADDS'90, pp.139-148, 1990.
- (9) 宝珍: "拡張可能データベース管理システム構築についての一考察", 情処第40回全大5H-1, 1990.
- (10) 宝珍: "拡張可能DBMS:COMMONの基礎的性能評価", 情処第41回全大1D-8, 1990.
- (11) 宝珍: "拡張可能DBMS:COMMONの格納構造について", 情処第42回全大1L-1, 1991.
- (12) 佐藤 他: "CAD技術を応用した地図処理システム", 情処データベースシステム研究会52-6, 1986.
- (13) R. Hull and R. King: "Semantic database modeling: Survey, applications, and research issues", ACM Computing Survey, Vol.19, No.3, pp.201-260, 1987.
- (14) 小野寺: グラフ理論の基礎, 森北出版, 1968.
- (15) 植村: データベースシステムの基礎, オーム社, 1979.
- (16) W. Kim: "A model of queries for object-oriented databases", Proc. of 15th VLDB, pp.423-432, 1989.
- (17) A. M. Alashqur et al: "OQL: A query language for manipulating object-oriented databases", Proc. of 15th VLDB, pp.433-442, 1989.
- (18) J. R. Abrial: "Data Semantics", in Data Base Management (J. W. Klimbie and K.L. Koffeman eds), pp.1-59, North-Holland, Amsterdam, 1974.
- (19) E.H. Sibley and L. Kerschberg: "Data architecture and data model considerations", proc. of AFIPS Nat. Computer Conf., Vol.46, pp.85-96, 1977.
- (20) A. Chan, S. Danberg, S. Fox, W. K. Lin, A. Nori and D. Ries: "Storage and access structures to support a semantic data model", Proc. of 8th VLDB, pp.122-130, 1982.
- (21) M. Hammer and D. McLeod: "Database Description with SDN: A semantic database model", ACM Trans. Database Sys., vol.6, No.3, pp.351-386, 1981.
- (22) D. Jagannathan et al: "SIM: A database system based on the semantic data model", Proc. of ACM SIGMOD'88, pp.46-55, 1988.
- (23) P. Pucheral et al: "Efficient Main Memory Data Management Using the DBGraph Storage Model", Proc. of 16th VLDB, pp.683-695, 1990.
- (24) 日本規格協会, 日本工業規格データベース言語NDL, JIS X 3004, 1987.
- (25) D. M. Campbell, D. W. Embley and B. Czejo: "A relationally complete query language for an entity-relationship model", Proc. of 4th Intl. Conf. on Entity-Relationship Approach, pp.90-97, 1985.