

分散データベースの質問処理における データ転送量の削減について

京大 工学部 吉川 正俊

上林 弘彦

矢島 倭三

1. まえがき

近年の計算機ネットワーク技術の進歩に伴い、分散型データベースはその重要性を増しつつあり、同種及び異種モデルに基づく実験システムが構築されている[ROTHB8003][SMITB8105]。分散型データベースにおける質問処理では各地点間のデータ転送に伴う通信コストを考慮に入れねば必要があり、集中型の場合とは異なるため処理アルゴリズムの開発が必要である。関係モデルに基づく同種型の分散型データベースシステムにおいて結合操作を効率的に実行するためには準結合操作が提案されており[BERNC8101]。準結合操作のみを用いて解くことができる質問は木型質問と呼ばれ、その処理の最適化に関する議論がいくつか行われてている[CHIU8005][CHI081]。ところが、木型質問以外の質問である巡回型質問に関しては、効率の良い処理方式はほとんど知られていない。我々は既に一般化準結

合操作を提案し、この操作を用いることにより任意の巡回型質問を解くことができるることを示した[KAMB8110]。本稿では巡回型質問の処理の効率化並びに仮性関数従属性（関係中に一時的に成立する従属性）を用いた処理の効率化について議論を行なう。

本稿の構成は以下の通りである。第2章では本稿で用いる用語及び記号の定義を行なう。第3章においては、文献[KAMB8110]で提案した巡回型質問の処理方法とデータ圧縮に関する基本的な説明を行ない、処理の一例を示す。第4章においては、単純巡回型質問をもとにすべての関係を1つの地点に集めて処理を行なう方法と一般化準結合操作を用い、質問全城木に沿って順次関係を転送して行く方法の通信コストの比較を行ない、ほとんどの場合前者に比べ後者の方がコストが小さくなることを示す。第5章では、一般化準結合操作に基づいた処理の際に用いる質問グラフの全城木として、質問グラフの推移的閉包の極大全城木を考え、一般的にはこの全城木に沿った処理がコストの点で有利となることを示す。また第6章では目的属性を含む関係が複数個存在する場合に対する考察を行なう。第7章では第3章で述べたデータ圧縮による前処理の一般化を行ない、第8章では仮性関数従属性を用いた(i) 巡回型質問の木型質問への変換、及び(ii) 転送データ

メモの圧縮について述べる。

2. 諸定義

属性 A_1, \dots, A_n からなる 関係 R とは、各属性の定義域の直積の部分集合である。 R の要素を 組 と言う。関係 R の属性集合を 関係スキーマ と言ひ $R(A_1, \dots, A_n)$ あるいは R でそれを表す。

A_{ik}, A_{jh} をそれぞれ R_i, R_j の属性とするとき $R_i \cdot A_{ik} = R_j \cdot A_{jh}$ の形の条件節の論理積結合を 等結合条件式 と言う。本稿では以後、結合する属性が等しいとき、すなはち $A_{ik} = A_{jh}$ の場合のみを考察の対象とする。データベースに対する質問は条件式 (qualification) と目的属性 (target attribute) から構成されるが、条件式が等結合条件式の場合にはその質問を 等結合質問 と言う。以後、等結合質問のことと単に質問と言う。また、目的属性を得るために必要な関係を 目的関係 といい、その集合を R_T で表す。

等結合質問 γ に対する 質問グラフ $G_\gamma(V_\gamma, E_\gamma, L_\gamma)$ はラベル付きの無向グラフである。ここで V_γ は節点集合であり、質問に現われる各関係に対して 1 つの節点が対応する。また質問 γ の条件式中に条件節 $R_i \cdot A = R_j \cdot A$ が存在するときまたそのときには限り節点 R_i と R_j の間を枝で結び、その枝にはこのよう

は属性 A のすべての和集合をラベルとして付ける。等価な質問に対応する質問グラフは互に等価であると言う。 G_θ と等価な質問グラフのうち枝数及びラベル数が最大のものを G_θ の 推移的閉包 といい、それを G_θ^+ で表わす。質問グラフが木で表わされる質問あるいはそれと等価な質問を 木型質問 といい、木型質問以外の質問を 巡回型質問 と言う。また、单一の閉路のみから成る質問グラフで表わされる巡回型質問を 单纯巡回型質問 と言う。

関係スキーマ \underline{R} に対して、 $X \in X \subseteq \underline{R}$ なる属性集合とするととき、関係 R の X 上への 射影 を $R[X]$ で表わす。2つの関係 R_1, R_2 に対して、次式で定義される属性集合 $\underline{R}_1 \cup \underline{R}_2$ 上の関係 $R \in R_1$ と R_2 の 自然結合 といい、それを $R_1 \bowtie R_2$ で表わす。

$$R = \{ t \mid \exists t_1 \in R_1, \exists t_2 \in R_2 \text{ s.t. } t[\underline{R}_1] = t_1 \text{ かつ } t[\underline{R}_2] = t_2 \}$$

関係 R_2 による R_1 の 準結合 は $R_1 \bowtie R_2$ で表わされ、次式で定義される。

$$R_1 \bowtie R_2 \triangleq (R_1 \bowtie R_2)[\underline{R}_1]$$

$X \in \underline{R}_1 \cap \underline{R}_2 \subseteq X \subseteq \underline{R}_2$ を満足する属性集合とするとき、 X における R_2 による R_1 の 一般化準結合 は $R_1 \bowtie_X R_2$ で表わされ、次式で定義される。

$$R_1 \bowtie_X R_2 \triangleq R_1 \bowtie R_2[X]$$

関係表において一時的に成立する関数従属性を 仮性関数従

属性(以後 SF や)と呼ぶ。

本稿では、分散型データベースを考え、この分野の他の大部分の研究にから、各関係は互いに異なる一つの地点に存在するものと仮定する。関係 R の存在する地点を $S(R)$ で表わす。また質問に対する答を最終的に求めてから地点を S_r で表わす。

3. 巡回型質問の処理方式とデータ圧縮

本章では、一般化準結合操作を用いた巡回型質問の処理方式及び通信コストの低減を目的としたデータ圧縮手法について述べる[KAMBRY8110]。

巡回型質問の処理方式の概要を以下に示す。ただし、ここでは $IR_T = \{R_T\}$ とし、目的関係 R_T において答の部分を同定するまでを考察の対象とし、答を S_r へ転送することは考えない。

- (1) 質問グラフにかかって R_T を根とする全域木を求める。
- (2) 全域木に属さない枝をすべて全域木に埋め込む。
- (3) 全域木の枝とそれに埋め込まれた枝のラベルの集合和を求める、それを全域木の枝の新しいラベルとする。
- (4) 全域木にかかって R_i を葉、 R_j をその親とし、 R_i と R_j を結ぶ枝のラベルを X とするとき、一般化準結合操作 $R_j = R_j \bowtie X R_i$ を実行し、全域木から節点 R_i を除去する。

(5) 全域木が節点 R_T のみに至るまで上記(4)を繰り返す。

次に例を示す。

[例1] 図1(a)に示す質問グラフを持つ巡回型質問について考えら。全域木として図1(b)の実線部で示された枝を選んだとすると、全域木に属さない枝(図1(a)では点線で示されてる)を全域木に埋め込み(図1(c)参照), ラベルの集合和を求むることにより, 図1(d)に示す全域木を得る。以後, この全域木に沿って一般化準結合 $R_2 \underset{CD}{\bowtie} R_3, R_1 \underset{BD}{\bowtie} R_2, R_T \underset{AD}{\bowtie} R_1$ を順に実行することにより, R_T の答の部分を求めることができる。□

一般化準結合では通常の準結合操作に比べ, 余分の属性の値を転送する必要が生じる。上記の例では, 通常の準結合操作に比べ属性Dの値を全域木に沿って関係 R_3 から R_T まで転送する必要があり, その分だけ転送データ量が増加する。したがって

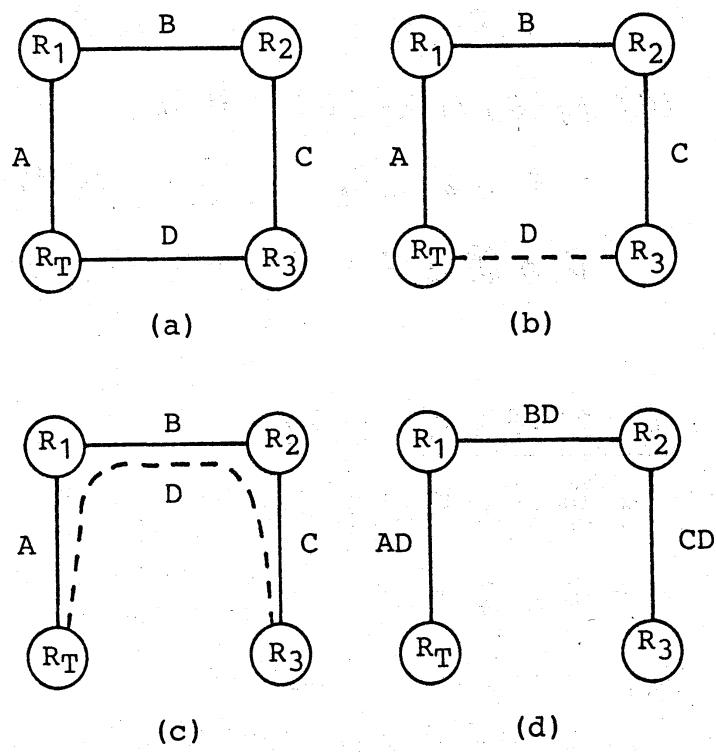


図1 巡回型質問の処理

転送データ量削減のため、次のようにデータ圧縮を行なう。すなわち、一般化準結合操作を実行する前に関係 R_3 と R_T の間で属性 D の値を交換し、 $R_3[D] \cap R_T[D]$ の部分のデータ値をすべて数値に置き換える。より厳密には、次の手順に沿って属性値の交換を行なう。ここでは $|R_3[D]| \leq |R_T[D]|$ の場合を示すが、逆の場合は R_3 と R_T をすべて入れ換えればよい。

- (1) $S(R_3)$ から $S(R_T) = R_3[D]$ を転送する。
- (2) $S(R_T)$ において $R_3[D] \cap R_T[D]$ を求める。
- (3) $R_3[D]$ の各値を 1 ビットに対応させたビットベクトルにおいて、 $R_3[D] \cap R_T[D]$ の部分を 1, 他を 0 とし、それを $S(R_T)$ から $S(R_3)$ に転送する。
- (4) $R_3[D] \cap R_T[D]$ の部分のデータをソートし、それを小さいものから順に 1, 2, … と数値符号化する。以後、属性 D の値はすべてこの数値によって表現する。

4. 処理方式の比較

本章では単純巡回型質問を解くための基本的な処理方式を考え、その通信量を比較する。

図 2 に示す単純巡回型質問を考える。 $R_T = \{R_T\}$ とし、前章

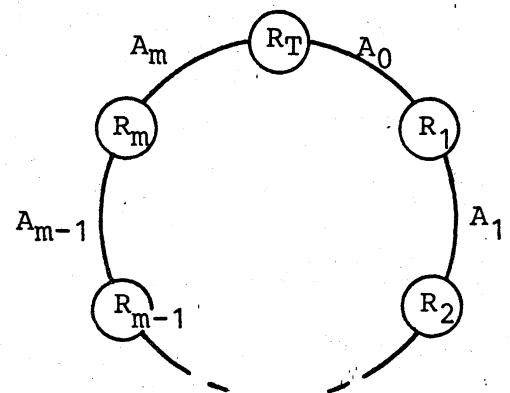


図 2 単純巡回型質問

と同様に $S(R_T)$ において答を得ることを目的とする。また各関係は 2 項関係であるとし、簡単のため各関係の組数は n 、各属性のフィールド長は d (ビット)、選択度 (selectivity) [CHEVNY80] は ρ とし、これらはすべての関係にわたって同一であるとする。このような条件のもとで次のような処理方法を考える。

方法 1： m 個の関係 R_1, \dots, R_m を直接 $S(R_T)$ に転送する。

方法 1'：隣接する関係間で属性値を交換し、データ圧縮を行なう後、 m 個の関係 R_1, \dots, R_m を直接 $S(R_T)$ に転送する。

方法 2： R_T を根とする質問グラフの全木 $R_T - R_m - \dots - R_1$ を考え、全木に沿って R_1 から R_T まで順に一般化準結合操作を繰り返す。

これらの中、方法 1 はいわゆる IFS (Initial Feasible Solution) [CHEVNY80] であり、巡回型質問を解くための最も単純な方法である。方法 1' は方法 1 に前処理としてデータ圧縮を加え改良したものであり、方法 2とともに我々がここで提案するものである。次にこれらの方法のデータ通信量を求める。

〈方法 1〉 データ通信量を T_1 とすると、 $T_1 = 2mnd$ となる。

〈方法 1'〉 前処理のためのデータ圧縮手法としては前節で述べた方法を用いる。関係 R_i と R_{i+1} ($i=1, \dots, m-1$)

の間でデータ交換を行なうための通信量は $(m-1)nd + (m-1)n$ である。この前処理により、関係 R_2, \dots, R_{m-1} の組数が p^2n に、関係 R_1, R_m の組数が pn になる。また属性 A_1, \dots, A_{m-1} の値はすべて数値符号化されているため、1つのデータを表現するためには高々 $\log pn$ ビットで十分である。したがって全体の通信量を T_1' とすると

$$T_1' = (m-1)nd + (m-1)n + 2(m-2)p^2n \log pn + 2pn(d + \log pn) \quad (1)$$

となる。 $\log pn = \delta$ と置くと (1) 式は

$$T_1' = n \{ (m-1)(d+1) + 2(m-2)p^2\delta + 2p(d+\delta) \} \quad (2)$$

と書くことができる。

〈方法2〉 まず、関係 R_T と R_1 の間で属性 A_0 の値を交換するためには $nd+n$ の通信量を必要とする。次に R_1 を $S(R_2)$ に転送するためには $pn(d + \log pn) = pn(d + \delta)$ の通信量を要する。 $S(R_2)$ は R_1 と R_2 の結合を行なうが、最悪の場合にはそれにより組数が非常に増加する。そこで結合によって落ちる組を 2 つの関係から取り除き残った組の属性 A_1 の値をすべて数値符号化するにとどめ、實際には結合を行なわない。この操作により、

関係 R_1, R_2 の大きさはそれを $2p^2n\delta, p^2n(d+\delta)$ とすり、したがって $S(R_2)$ から $S(R_3)$ への通信量は $p^2n(d+3\delta)$ となる。以下、同様にして一般に $S(R_i)$ から $S(R_{i+1})$ ($i=1, \dots, m$, ただし $R_{m+1} = R_T$ とする。) への通信量は $p^{2n}\{d + (2i-1)\delta\}$ となる。したがって方法 2 による全通信量は

$$\begin{aligned} T_2 &= nd + n + np(d+\delta) + \dots + np^m\{d + (2m-1)\delta\} \\ &< nd + n + np(d+\delta) + \dots \\ &= n \left\{ 1 + \frac{d}{1-p} + \frac{p(1+p)\delta}{(1-p)^2} \right\} \end{aligned} \quad (3)$$

となる。

$n=10,000$ と $i=2$ で T_1, T'_1, T_2 の比較を行なう。 T_1 と T'_1 は関しては、 $d \geq 4$ バイトのときは必ず $T_1 > T'_1$ が成立する。また $d=3$ バイト、2 バイト、1 バイトのときは、それとれども $p \leq 0.94$ 、 $p \leq 0.76$ 、 $p \leq 0.66$ において $T_1 > T'_1$ が成立する。このことからほとんどのすべての場合において方法 1 よりも方法 1' の方がデータ転送量が少くなると言える。

そこで次に T'_1 と T_2 の比較を行なう。 $p \leq 0.29$ においては $T'_1 > T_2$ となり、また $m=2$ の場合を除けば $p \leq 0.48$ において $T'_1 > T_2$ となる。これらの場合は必ず方法 2 の方が通信量が少くなる。との他の場合は一般に m, d の値が大きく、 δ の値が小さい程、方法 2 の方が有利となると言える。 T_2 の計算

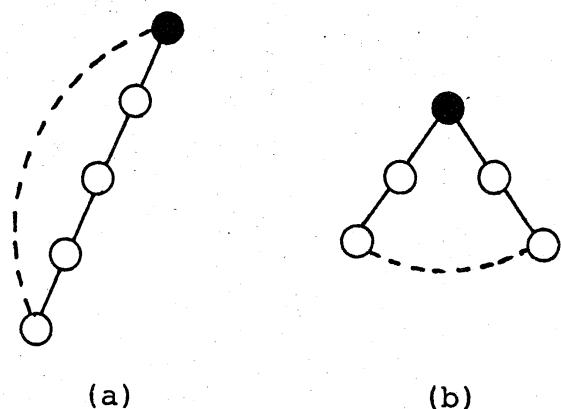
に関しては最悪の場合を見積つておるために、実際に方法2が有利となる条件はより広いものと思われる。通常の質問処理では前処理として各関係に対して制約操作を施すため、選択度 α は一般に小さな値を持つと考えられる。以上より、ほとんどの場合は方法2の方がデータ通信量が少いが、特殊な状況（たとえば $m=2$, $\alpha \approx 1$ など）のもとでは方法1'の方が有利であると言える。したがって状況に応じて方法1'と方法2を使分けの必要がある。

5. 全域木の選択

前章で行なった比較より、通常の場合単純巡回型質問は図3(a)に示す形の全域木（図中、●印は根を表す）に基づいて処理を行なえば選択度の効果が蓄積して行くために全体のデータ通信量が小さくなるという結果が得られた。一般的質問グラフは複数個の閉路を含

るが、全域木として深さ優先による全域木 (depth-first spanning tree) を選べば、すべての閉路を図3(a)の形にすることができる [AHō-H74]

(ただしこの場合、図中 ●印



(a) (b)

図3 全域木の選択

は根ある、は根に最も近い節点を表わし、点線は逆辺(back edge)を表わす。) したがって、深さ優先による全探索木に基づけば、すべての閉路に関して選択度の蓄積を最大とすることができる。ところが、場合によっては全探索木に属さない枝(全探索木に埋め込む必要のある枝)にラベルとして多くの属性を持つものが残る可能性があり、その場合には全探索木に沿って結合属性以外の多くの属性のデータを転送する必要が生じ、必ずしも効率的でない。例を示す。

[例2] 図4(a)の

質問グラフに基づいて考

える。図中、●印の関係

は R_T を表す。図4(b)

に示される深さ優先の全

探索木を考えた場合、全

探索木に属さない枝のラベル

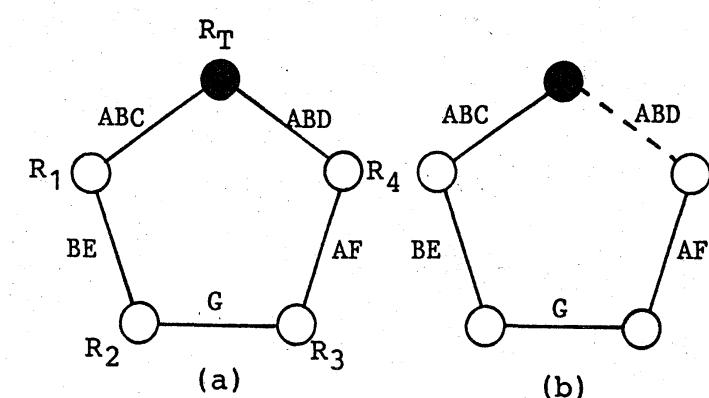
は ABD である。したが

って質問処理のためにには

属性 A, B, D の値を全

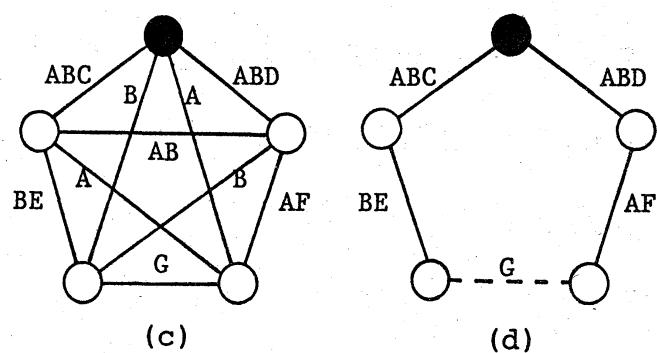
探索木に沿って R_4 から R_T まで

送する必要がある。



(a)

(b)



(c)

(d)

図4 質問グラフの深さ優先の全探索木及び極大探索木に基づく質問処理

□

深さ優先の全探索木には上述のような問題点がある。そこで全探索木に埋め込む必要のある枝数及びラベル数をなるべく少くするために、各枝のラベル数をその枝の重みと見なした場合の質問グラフの推移的閉包 G_q^+ の極大全探索木を考える [BERNG79/2]。次の命題が成立する。

[命題 1] 巡回型質問の処理において、質問グラフ G_q の全探索木として推移的閉包 G_q^+ の極大全探索木を選択すれば、全探索木に埋め込む必要のあるラベル数は最小となる。 □

ただし命題 1 では同じ属性名でも異なる枝にあれば異なるラベルとして考えらるものとする。以上の結果より、全探索木として深さ優先による全探索木及び G_q^+ の極大全探索木を考えた場合、両者の間には選択度の蓄積及び全探索木に埋め込む必要のあるラベル数についてトレードオフが存在することがわかる。ところが全探索木として G_q^+ の極大全探索木を選択した場合でも、次のような処理方法により選択度の蓄積について深さ優先の全探索木と同等の効果を得ることができ。既ち、 G_q^+ の極大全探索木に基づく場合は、質問グラフ中の閉路が図 3(b) のように刀形で現われることがあるが、その場合には全探索木の葉(或いは葉に最も近い節)から根(或いは根に最も近い節)に至る 2 つの経路のうち、一方の経路に沿った処理を行ない、次に根と他の葉の葉の間でデータを交換することにより最

初に処理を行なうた経路の選択度の蓄積効果を他方に伝えろ。その後、他方の経路に沿って残りの処理を行なう。この方法によれば、実質的に閉路中のすべての関係を直列に並べ順に処理を行なう場合と同等の選択度の蓄積効果を得ることができる。

[例3] 図4(a)の質問グラフの推移的閉包及びその極大全域木をそれぞれ同図(c), (d)に示す。全域木に埋め込む必要のあるラベル数は同図(c)の場合が3に対し、(d)の場合は1である。同図(d)の全域木に基づく処理としてはまず R_2 から R_T に至る経路に沿って一般化準結合 $R_1 \underset{BEG}{\boxtimes} R_2, R_T \underset{ABCG}{\boxtimes} R_1$ を順に行なう、次にこの操作によって得られた選択度の蓄積効果を関係 R_3 に伝えるために、 R_T と R_3 の間で属性 G の値を交換する。その後はもう一方の経路に沿って $R_4 \underset{AFG}{\boxtimes} R_3, R_T \underset{ABDG}{\boxtimes} R_4$ をこの順に実行する。口

6. 目的関係が複数の場合への拡張

前章までは、 $|R_T| = 1$ の場合のみを考察の対象として来たが、一般には目的関係が複数個存在する場合、或いは結合属性が目的属性となっている場合などを考える必要がある。

[例4] 4つの関係スキーム $R_1[A, C], R_2[B, C], R_3[B, D], R_4[C, D]$ に対して、図5の質問グラフで与えられ

る巡回型質問を考える。目的属性を $\{A, B\}$ とした場合、目的関係 IR_T として $\{R_1, R_2\}$, $\{R_1, R_3\}$ の2つの集合を考えることができる。□

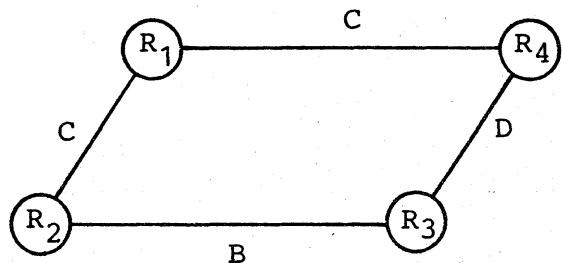


図5. 質問グラフ

上記の例から明らかのように、結合属性が目的属性となつてゐる場合は目的関係 IR_T が一意に決定まつたまゝである。目的属性の集合が与えられたとき要素数最小の IR_T を求める問題は集合の最小被覆問題そのものであるが、 IR_T を求める場合にはさうに IR_T に属する関係が質問グラフ中で互いに近い位置に存在すべきであるという条件を加えることができる。例えば[例4]では IR_T として $\{R_1, R_2\}$, $\{R_1, R_3\}$ が考えられるが、前者の場合には質問グラフにおいて2つの関係が隣接しているのに對し、後者ではそうではなかつていい。最終的に答を S_T に転送することを考えると、 $IR_T = \{R_1, R_3\}$ の場合では、 R_1 と R_3 の関連を知るために R_2 や R_4 をも S_T に転送する必要がある。データ転送量削減のためににはこの方法は得策ではなく、したがつて[例4]の場合には $IR_T = \{R_1, R_2\}$ とすべきである。

7 データ圧縮による前処理の一般化

本章では、第3章で述べたデータ圧縮による前処理の手法の一般化を行なう。図6に示す巡回型質問を考

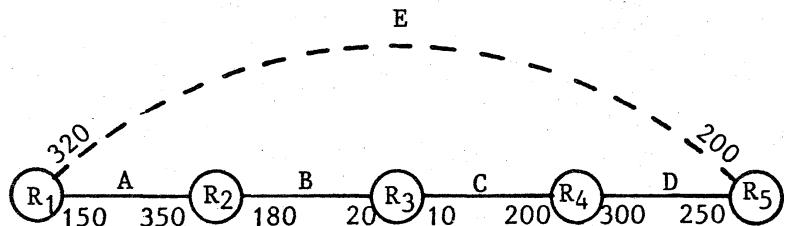


図6 データ圧縮による前処理の一般化

える。 $R_T = \{R_1\}$ とし、図中の数字は前処理として各関係に対する制約操作を実行した後の各属性の異なる属性値の数を示す。図からわかるようにこの例では R_3 の組数が小さい。このようない場合は R_5 から R_1 に向かう順に一般化準結合操作を実行する処理手法よりも、以下に示すような順で処理を行なった方が全体の処理コストが小さくなると考えられる。

- (i) $R_4 \times R_3$
- (ii) $R_5 \times R_4$
- (iii) $R_1 \times R_5$
- (iv) $* R_5 \times R_1$
- (v) $* R_4 \times R_5$
- (vi) $* R_3 \times R_4$
- (vii) $R_2 \times R_3$
- (viii) $R_1 \times R_2$

*印を施した処理は、2章で述べたビットベクトルによるデータ圧縮手法を用いたものであり、そのデータ転送量は他の処理に比べてかなり少くなる。より一般的には組数早いは選択度の最も小さい関係から処理を開始すべきである。

8. 仮想関数従属性の利用

8.1 巡回型質問の木型質問への変換

図7(a)の質問グラフ(同図(c)の質問グラフと等価)で表される巡回型質問について考える。今、関係 R_2 ある $\rightarrow R_3$ において $SFD: D \rightarrow C$ が成立すると仮定する。このとき準結合 $R_3 \underset{CD}{\times} R_2$ 及び $R_2 \underset{CD}{\times} R_3$ を実行することにより、関係 R_2 及び R_3 の地点において $R_2[CD] \cap R_3[CD]$ の部分を固定できること。 $R_2[CD] \cap R_3[CD]$ で $SFD: D \rightarrow C$ が成立するため、これ以後、関係 R_2 と R_3 の間では属性 D の値を転送するだけで十分である。すなわち図7(c)の質問は図7(d)の質問と等価となる。ところが図7(c)の質問は図7(d)の質問と等価であり、したがって木型質問である。すなわち、関係表において成立する SFD を利用することにより巡回型質問を木型質問に変換でき、準結合操作のみを用いて解くことが可能となる。

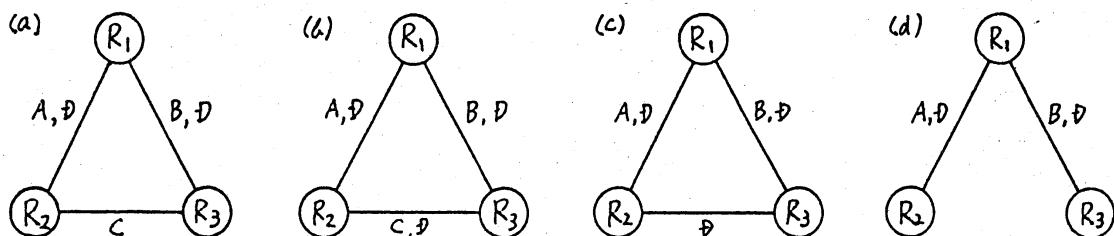


図7 SFD を用いた巡回型質問の変換

8.2 転送データ量の削減

SFDを利用することにより、転送データ量を削減できる場合がある。関係 R_1 と R_2 を属性 A, B で結合する場合を考える。この結合を準結合操作を用いて処理するためには $R_1 \underset{AB}{\times} R_2$, $R_2 \underset{AB}{\times} R_1$ を実行する必要がある。ところが関係 R_2 において $SFD: A \rightarrow B$ が成立する場合は、 R_2 に対しては属性 A の値を指定するだけで属性 B の値が一意に決まる。したがって先の準結合操作では $R_2 \underset{AB}{\times} R_1$ を実行するかわりに $R_2 \underset{A}{\times} R_1$ を実行するだけで十分である。一般には質問で指定された関係において複数個の SFD が成立する場合を考えられるが、必ずしもすべての SFD を転送データ量の削減に利用することはできない。例えば図 8 に示す質問グラフにおいて $C \rightarrow A$ あるいは $C \rightarrow B$ をそれぞれ単独に利用することは可能である

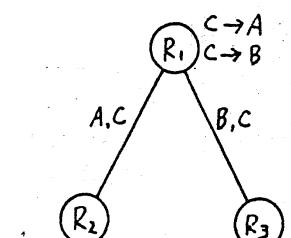


図 8 質問グラフ

が、両者を同時に利用できない。

また結合属性を A, B, C とし、各属性間に $SFD: A \rightarrow B, B \rightarrow C$ が成立する場合は、転送する関係を 2 つに分解した方が一般的にデータ量が削減される。

8.3 SFD の検出

実際の関係表において $SFD: A \rightarrow B$ が成立していることを検出するためには、関係表を属性 A の値でソートし、属性 A

の一つの値に対しては属性Bの値がただ一つ決まることを調べる必要があるが、これは非常に時間のかかる処理となる。そこでSFDの検出のためには、まず圧縮関係[KAMBY8109]などを用いてその成否を調べ、圧縮関係上で成立したSFDの片に關し、実際の関係上で検出操作を実行するなど、処理時間削減のための工夫が必要である。

謝辞　日頃、御討論頂く矢島研諸氏に深謝する。又ち、本研究は一部、文部省科学研究費による。

参考文献

- [AHO-H74] Aho,A., Hopcroft,J. and Ullman,J., The Design and Analysis of Computer Algorithms, Addison-Wesley, 1974.
- [BERNC8101] Bernstein,P.A. and Chiu,D.M., "Using Semi-Joins to Solve Relational Queries", JACM, Vol.28, No.1, pp.25-40, Jan. 1981.
- [BERNG7912] Bernstein,P.A. and Goodman,N., "Full Reducers for Relational Queries Using Multi-Attribute Semi-Joins", IEEE Computer Networking Symposium, pp.206-215, Dec. 1979.
- [CHIUB81] Chiu,D.M., Bernstein,P.A. and Ho.Y.C., "Optimizing Chain Queries in a Distributed Database System", Harvard Rep., 1981.
- [CHIUH8005] Chiu,D.M. and Ho.Y.C., "A Methodology for Interpreting Tree Queries into Optimal Semi-Join Expressions", ACM-SIGMOD'80, pp.169-178, May 1980.

- [HEVN 80] Hevner,A.R., "The Optimization of Query Processing on Distributed Database Systems", Ph.D Diss., Tech. Rep. DB-80-02, Dept. of Computer Sci., Purdue Univ., 1980.
- [HEVNY7905] Hevner,A.R. and Yao,S.B., "Query Processing in Distributed Database Systems", IEEE Trans. on Software Engineering, Vol.SE-5, No.3, pp.177-187, May 1979.
- [KAMBY8109] 上林弥彦,吉川正俊,矢島脩三 “分散型データベースシステムにおける圧縮関係の利用”, 信学技報, AL81-53, 1981年9月.
- [KAMBY8110] 上林弥彦,吉川正俊,矢島脩三 “一般化準結合を用いた質問処理について” 信学技報, AL81-70, 1981年10月.
- [ROTHB8003] Rothnie,J.B.Jr., Bernstein,P.A., Fox,S., Goodman,N., Hammer,M., Landers,Y.A., Reeve,C.L., Shipman,D.W. and Wong,E., "Introduction to a System for Distributed Database(SDD-1)", ACM Trans. on Database Systems, Vol.5, No.1, pp.1-17, Mar. 1980.
- [SMITB8105] Smith,J.M., Bernstein,P.A., Dayal,U., Goodman,N., Landers,Y., Lin,K.W.T. and Wong,E., "Multibase --- Integrating Heterogeneous Distributed Database Systems", AFIPS NCC'81, Vol.50, pp.487-499, May 1981.