

従属性を考慮したネットワークデータベースの設計

京大工学部 上林彌彦 (Yahiko Kambayashi)

京大工学部 古川哲也 (Tetsuya Furukawa)

1. まえがき

1970年のCoddによるデータベースの関係モデルの導入により、データベースの理論的研究が大きく進展した。1980年代に入り、これらは、関係データベースの商用システムがIBMをはじめとする各社より発表され、従来のデータベースシステムでは応用の困難な分野にも利用されはじめている。⁽¹⁾しかしながら、効率という面から考えると、従来のネットワークモデルによるデータベースは非常にすぐれています。関係モデルのみならず、ネットワークモデルや階層モデルによるデータベースも今後利用されやすくなると考えられます。

ネットワークモデルによるデータベースの欠点の1つは、組織的な設計方法が存在しないということで、設計者の経験と直感にたよる設計が一般に行なわれています。従来の方法と1つは、「実体関連図を用いて1対1, 1対多、多対多の対

応関係とともに設計するもの」や「関数従属性を用いたもの」⁽²⁾⁽³⁾が知られていく程度で、種々の条件を複合したもののは知られていなかった。ネットワークモデルはどのように意味制約を表わしているかは文献⁽⁴⁾を参考しているが、本稿ではその結果を用いて関係データベース理論の成果をどのようにネットワークデータベースの設計に反映できるかについて検討する。

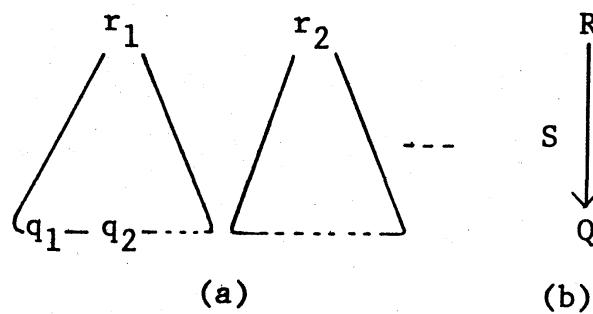
2. 基本的事項

ネットワークモデルにおけるレコード型は、同じ属性集合からなるレコードの集合である。属性は CODASYL ではデータ項目と呼ばれている。あるレコード型（親レコード型）の一つのレコード（親レコード）に別のレコード型（子レコード型）の任意個数のレコード（子レコード）を関連づけて全体に名前をついたものを親子集合といい、親レコード型のすべてのレコードに対して作られる。親子集合は図 1 (a) に示す多重リンクで表現される。

r_1, r_2, \dots は親レコード型

R のレコード, s_1, s_2, \dots

は子レコード型 Q のレコードである。



親子集合を個々 図 1 親子集合と親子集合型

のレコードではなくレコード型の関係と1つ記述したものと親子集合型といい、 $S \langle R, Q \rangle$ で表わす。Sは親子集合型の名、R,Qはそれぞれ親レコード型、子レコード型である。

ネットワークモデルの構造は、ハックコン線図と呼ばれる有向グラフ (N, E) で表わされる。Nは各レコード型に対応する節点集合、Eは各親子集合型に対応し、親レコード型に対応する節点から子レコード型に対応する節点へ向かう有向枝の集合であり、親子集合型名のラベルをつけることがある。 $S \langle R, Q \rangle$ は図1(b)で表わされる。

本稿では、関係モデルと同様に $R(U)$ で構成する属性集合がUであるレコード型Rを、ト[X]でレコードトの属性集合Xの値を表わす。値が定まれば対応する $R(U)$ のレコードがただ1つ定まるような最小の属性集合KをRのキーと呼ぶ。Rのレコードに複数が存在する場合があるのを、必ずしも $K \subseteq U$ である必要はない。キーは複数個存在してもよいが、本稿では一般性を失なわず簡単のため1つだけであると仮定している。

従属性と1つは、閑数従属性 (FD)、多値従属性 (MV D)、存在従属性 (ED)を考える。属性集合Xが属性集合Yに従属であるのは、それぞれ $X \rightarrow Y$ 、 $X \rightarrow\! Y$ 、 $X \vdash Y$ で表わす。FD、MV Dは空値まで拡張したもの⁽⁴⁾⁽⁶⁾とする。

3. スキーマ設計時の問題点

データベースシステムは、個々の利用者の持つデータをまとめるにより冗長度を減らし、全体のデータを統一的に管理する一方、利用者に対する正しいデータを供給する必要がある。そのため、スキーマ設計に際して次のような条件を考慮する必要がある。

- (1) データの冗長性の除去
- (2) 質問に対する処理の効率化
- (3) 意味制約の保持

冗長性をなくすことは、データベースの本来の目的の一つであり、データの挿入・更新・削除の際にデータ間の矛盾いや不整合を防ぐ。また、予めどういう質問が多いのかかわらず、ついには、それらの質問を処理しやすい設計を行なうべきである。質問処理とスキーマの適合性の判断基準も必要となる。⁽⁵⁾しかし、質問処理の効率化のために冗長性を持たせた方がよい場合が多い。

実世界でデータが持つ意味制約をスキーマ設計に反映させることは、正しいデータの供給の上で重要となる。また、意味制約からデータの冗長性を判断できる場合が多い。だが、意味制約について何を考えるか、例えば、関係データベース理論における各種の従属性や時間的な制約、動的な制約などの

うちどこまでスキーマ設計に用いればよいかという問題点もある。

4. 親子集合が表現できる意味

ネットワークモデルに対するスキーマ設計を行なう場合、その構造の基本単位である親子集合がどのような意味を持つのか、どのような目的で使われていいのかを明らかにしなければならない。この親子集合の意味が明確でないことが、スキーマ設計が経験的・直感的となつていい原因の一つである。本節では、親子集合が表わす意味を明確にすると共に、それとの意味の関連についても考察する。

親子集合は、親レコード型の1つのレコード型に対し、子レコード型の複数のレコード型を対応させている。この構造はデータ間の1対多の対応関係だけではなく、いろいろな意味で使われていいと考えられ、

- (1) 関数従属性の表現
- (2) 検索のための索引構造
- (3) 冗長性の除去
- (4) 存在従属性の表現
- (5) 利用者のビューと考えられる値の保持
- (6) 属性値に対する一貫性の保持

をあげることができます。

4.1 関数従属性とデータの類別

(1) は親子集合の構造とのものか子レコード型から親レコード型への関数従属性 (FD) を表すものと見ることができます。一般にも指摘されていきますが、FD集合を用いたネットワークモデルのスキーマ設計に関する研究もなされています。⁽²⁾⁽³⁾ FDの表現は、データ間の1対多の対応を表すだけでなくデータの類別にも用いられます。例えば、年令 (20才未満、20代、...) や頭文字による類別を行なう場合、グループ名を親レコードとする構造で表現できます。こども値が定まればその属するグループが決定することから一種のFDの表現である。

4.2 検索のための索引構造

データベースの設計を行なう際に質問処理の効率化が一つの重要な要因であることは3節で述べた。(2)の検索のための索引構造は、検索のキーとなる属性集合を親レコード型とする親子集合型である。

[例1] レコード型 R (A B C) で、属性 A の値を指定して

R のレコード α を求める質問が多いとき、例えば "A の値が a である $B C$ の値を求めるときは、一般に R には $\alpha[A] = a$ であるレコード α が複数個存在するので R のレコードをすべて調べる必要がある。ここで、レコード型 $S(A)$ を作り、 A の値が一致する R のレコードをまとめて親子集合型 $\langle S, R \rangle$ を作る (図2(a)) と、 $\alpha[A] = a$ である S のレコード α を検索すれば、求めたい R のレコードは α を親レコードとする親子集合の子レコードと 1 つ得ることができる。 A の値の種類が m 、 A の 1 つの値に対する R のレコードが n (簡単のためすべて同じ数とする) であれば、 R のレコードの総数は $m \cdot n$ となる。(図2(b)) S によって索引構造をつくれば、 α を得るのに検索するレコードの数は平均で $m/2$ 、最悪でも m である。従って、求めたい

R のレコードを得るのに平均 $m/2 + n$ 、最悪でも $m+n$ のレコードを検索するだけでよく、もとの $m \cdot n$ に比べると大幅に減らすことができる。

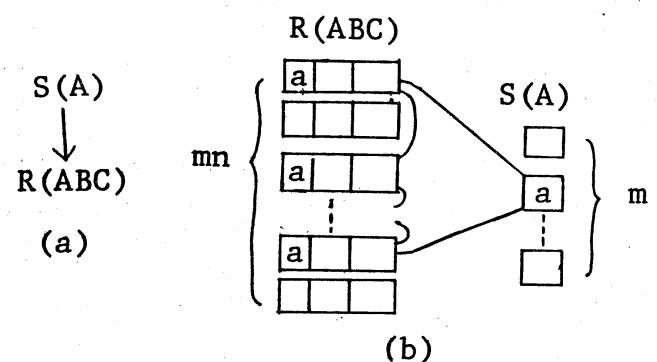


図2 親子集合による検索

4.3 冗長性の除去

親子集合による冗長性の除去は次の場合に分けて考えるこ
とができる。

(3-1) 1つの親子集合型で親レコード型と子レコード型
に共通の属性集合がある。

(3-2) 1つのレコード型で値が重複する属性集合がある。

(3-3) 複数のレコード型で共通の属性集合がある。

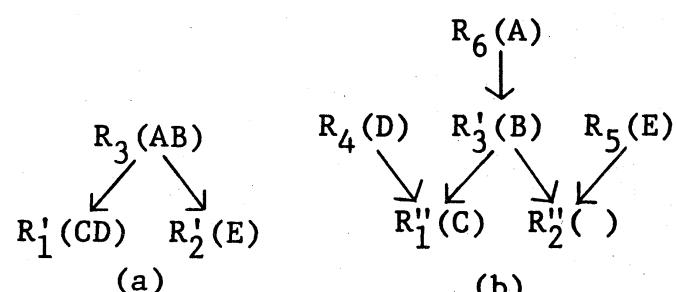
1つの親子集合型で、親レコード型と子レコード型に共通
の属性集合があり、各親子集合ではその属性集合の値が一致
しているとき、その値は親レコードで代表することができる
ので子レコード型ではその属性集合は冗長なものとなる。(3
-1) は这样的な属性集合を子レコード型から除去できる場
合である。

(3-2) は値が重複する属性集合からなるレコード型を作
り、それを親とする親子集合型を作ることによつて(3-1)
を適用するものである。例1では、 $R(ABC)$ に対し値の重
複する属性 A を親レコード型と 1 つ親子集合型 $\langle S, R \rangle$ を作
た。 R のレコードの A の値はその親レコードと同じであるの
で、 $R(ABC)$ を $R'(AB)$ にすることができる。

(3-2) を複数のレコード型にまで拡張したのが(3-3)
である。属性集合 X を含むレコード型 $R_1(Y_1X), R_2(Y_2X),$
 $\dots, R_n(Y_nX)$ ($Y_i \cap X = \emptyset, 1 \leq i \leq n$) はレコード型 $S(X)$

を親とする親子集合型 $\langle S, R_1 \rangle, \langle S, R_2 \rangle, \dots, \langle S, R_n \rangle$ を作ることによつて属性集合 X を除くことができる。この操作によつて、1つの属性の値はただ1つだけデータベースに記憶されるような構造にすることも可能である。

[例2] レコード型 $R_1(ABCD)$, $R_2(ABE)$ で、FD : $B \rightarrow A$, $C \rightarrow BD$ が成り立つものとする。 R_1 のキーは C, R_2 のキーは BE である。 R_1 と R_2 の共通属性は AB であり、その値は R_1, R_2 で重複して現われる。従つて、レコード型 $R_3(AB)$ を作り、 R_1, R_2 を $R'_1(CD), R'_2(E)$ とすることによつて AB の値の重複を避けることができる。(図3(a)) R'_1 では C がキーなので D の値のみが重複し、 R'_2 では E のみではキーはないないのでその値は重複する。 R_3 では B がキーとなるので A の値が重複する。従つて、レコード型 $R_4(D)$, $R_5(E)$, $R_6(A)$ を作り、図3(b) とすることができる。 R''_2 は、データを持たないホールドのレコード型



となります。

図3 冗長性の除去

冗長性を除くと質問処理が遅くなる場合がある。例えで、

$C = c$ であるような D の値を求めるたいとき、図3(a)ではレコード型 $R'_i \geqslant r[C] = c$ であるレコードを検索すればよいのに対し、(b)では $R''_i \geqslant r[C] = c$ となるレコードを検索し次に $\langle R_4, R''_i \rangle$ の親子集合のポインタをたどり r の親レコードを求めなければならぬ。いわゆる time / space trade off であるが、これは設計時に検討を要する問題である。

4.4 存在従属性の表現

親子集合では、子レコードには対応する親レコードが存在する。つまり子レコード型に含まれる属性集合 X の値が存在するこ親レコード型の属性集合 Y の対応する値が存在するので、存在従属性 (ED): $X \rightarrow Y$ を表わすことができることを考えられる。しかし、これは挿入属性や保留属性の指定によって実現されるものであり⁽⁴⁾ 必然的なものではない。

4.5 ビュー的値の保持

(5) はレコードの集合から得ることができるべき値を親レコードに記憶しておくもので、

(5-1) 属性値集合の代表値を記憶する。

(5-2) ある属性の集約値を記憶する。

の二つを考えることでよい。時間的経歴を記憶していると

きの最新値や候補の中で現在有効な値（1つの候補集合の中では有効値はただ1つの場合に限る）などは（5-1）であり子レコードの属性の和や平均、レコードの数などは（5-2）である。これららの値は子レコードを検索することによつて得られる値である。

[例3] 商品との価格の移り変わりのデータベースを考える。商品名を親レコード、その価格を子レコードとする親子集合を作ればよいか、子レコードの中での最新の値、即ち現在の価格は商品名と共に親レコードに記憶しておくことが考えられる。（図4(a)）また、商品を商品群として類別する場合には、4.1よりグループ名を親レコード、商品名を子レコードとする親子集合で表現が可能か、商品群ごとの商品の種類の数や平均価格 $R_1(\text{商品名}, \text{現価格})$ $R_3(\text{商品群}, \text{商品数}, \text{平均価格})$ 格を親レコードと共に記憶することも考 \downarrow \downarrow $R_2(\text{価格}, \text{日付})$ $R_1(\text{商品名}, \text{現価格})$ (a) (b) えられる。（図4(b)）

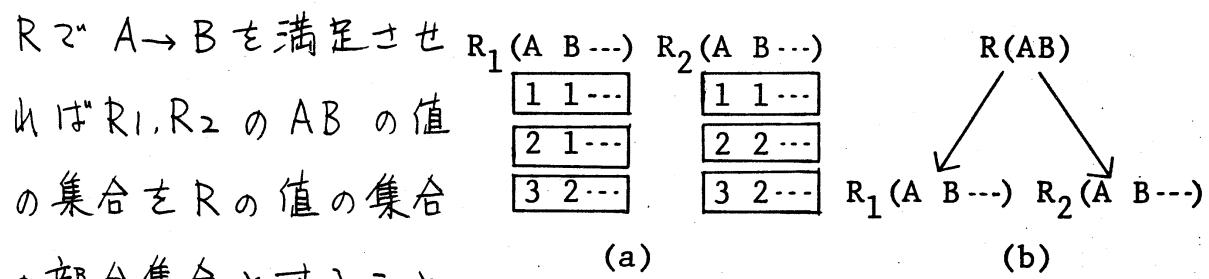
図4 代表値と集約値

4.6 属性値に対する一貫性の保持

一貫性の保持は、同じ属性集合かとりうる値の集合か同一であることを保障するものと、各種従属性の保持とかある。

複数のレコード型に現われる属性集合を1つの親レコード型とまとめることは、一貫性の保持にも用いられる。

[例4] 属性ABを含む2つのレコード型R₁, R₂があり、R₁, R₂では共にAからBへのFDを満足しても全体としては満足していない場合がある。R₁とR₂のレコードが図5(a)であるとするとき、それだけでFD: A→Bを満足しているか、全体としてはAの値2に対しBの値は1と2の2つしか存在し、この従属性を満足していない。新たにレコード型R(AB)と親子集合型<R, R₁₂>を作り(図5(b))。



の部分集合とすること

によると一貫性を保つ

ことができます。

図5 一貫性の保持

一般に、属性集合X, Yを含むレコード型が複数個存在したときのXの値とYの値の対応についての一貫性は、XYからなるレコード型Rを作り、Rを親レコード型とする親子集合によって保つことができる。同様の考え方によると、定義

域間の包含関係も親子集合で扱うことができます。データの更新時には、XYの値が同じレコードはRのレコードを介してすべてつながっているので更新も山を附ぐことができます。また、4.3より子レコード型の属性集合XYは削除することができる。このとき、XYの値の変更はデータベース全般にわたるときはRのレコードの値の変更で、ある特定のレコードに対する変更は親子集合の組換えが可能である。

次に従属性の保持であるが、FDは4.1で述べたように親子集合型に反映させることによつて保持される。EDについても親子集合型で保持される場合がある。親子集合の集合による多値従属性(MVD)を保持される。⁽⁴⁾⁽⁶⁾ 1対1、1対多の意味制約はFDで表現できる。多対多の表現は、途中に冗長なレコード型を導入した2つの親子集合型で表わされる。従来の実体関連図よりのネットワークデータベースの設計では、1対1、1対多、多対多の意味制約の反映が基本となる。

利用者のビューと考えられる値も、代表値はその候補となる値の集合を1つの親子集合でまとめるによつて、集約値は計算に要する値の集合を親子集合と1つまとめるによつてそれらの値の一貫性を保たれていいかどうかが容易に検査される。

以上のように、親子集合は様々な意味で用いられており、それそれには独立ではない。これらの意味がうまく合致するようにスキーマ設計を行なわなければならぬのか、本節で述べたような細かい分析はほとんど行なわれていなかつたため、スキーマ設計が経験的直感的なものになつてゐる。

5. ネットワークデータベースの設計

本節では4節での議論を基に、ネットワークデータベースの設計法に対する基本的な考慮を与える。設計の順序は、

- (1) データに対する制約の保持
- (2) 質問処理に対する効率を上げるためにの変更
を行ない、同時に冗長性についても考慮する。

データに対する制約としては各種従属性を与える。質問処理の効率の向上のためには、特定の属性に対する索引の生成、子から親へたどる場合を減らすための設計の変更、親子集合における子レコードの順序の決定、集約値や特定の値の親レコードへの埋め込み等を考えられる。

FD: $X \rightarrow A$ はその意味によつて
 type I: X A を 1 つのレコード型にまとめおくもの
 type II: 親子集合型で表現するもの
 の 2 つに分けられることかであります。type I は、X と A の値の対応

が1対1に近い場合、Aが集約値を表す1つい子場合、代表的な質問にAの値を指定して検索を行なうようなものかない場合など、親子集合で表現する必要性があまりないものである。typeⅡは、Aの値を指定して検索を行なう質問が多いと考えられる場合、E/Rを構造で表現したい場合などがある。

次に実際の例を用いてネットワークデータベースを設計する。

[例5] 属性と1つ次のものを考える。

先生、(先生の)年令、科目、単位数、(科目の)平均点、点数、評価、学生、(学生の)住所、修得単位、入学年度、講座、(講座の)責任者

代表的質問と1つ次のものがあるとす。

Q1: ある年度に入学した学生すべてについて、学生順に修得単位と学生名を求めるよ

Q2: すべての科目についてその担当者と平均点を求めるよ

Q3: すべての学生について、点のよいものから10科目、科目名と点数を求めるよ

Q4: すべての講座について、それに所属する先生と学生を求めるよ

Q5: 評価が優秀の学生かい子科目を求めるよ

86：ある科目に対し、成績が優秀な者と人を求める
次のようなFDが成立している。

先生→年令：type I 先生の人数が少ないと1対1に近く。
年令からの検索もない。

先生→講座：II 講座からの検索(84)がある。

科目→平均点：I 平均点は集約値である。

科目→単位数：I 単位数からの検索はない。

学生→住所：I ほとんど1対1である。

学生→講座：II 講座からの検索(84)がある。

学生→修得単位：I 集約値である。

学生→入学年度：II 入学年度からの検索(81)がある。

学生・科目→点数：I 点数からの検索はない。

点数→評価：II 評価からの検索(85)がある。

講座↔責任者：I 1対1の対応である。

MVD、EDは次のものがある。

科目→先生：1つの科目を複数の先生が担当する。

先生+講座：すべての先生はどこかの講座に属している。

科目+先生：すべての科目には教え子先生が多い。

学生+入学年度：すべての学生は入学年度をもつ。

講座+責任者：すべての講座には責任者が多い。

FD、MVDより、図6(a)とすることとする。

レコード型 $R(X)$ のキーを K とする。レコード型 $S(Y)$ で $Y \ni K$ であれば、 $FD: Y \rightarrow X$ が成り立つので親子集合型 $\langle R, S \rangle$ を作ることができる。図 6(a) では、 R_4 は R_1 のキー "科目" と R_7 のキー "学生" を含むので、それぞれの子レコード型とすることができる。

$ED:$ 科目 + 先生 は

R_1 のレコードには必ず対応する R_3 のレコードが存在し、 R_3 のレコードには必ず R_5 のレコードが存在するという制約になる。

子レコード型が親レコード型に存在従属であるのは、挿入属性と保留属性によつて表わすことができる。この例では、データの意味からどの親子集合型についても子レコードには対応

R_1 (科目、単位数、平均点)

R_2 (入学年度)

R_3 (科目、先生)

R_4 (科目、学生、点数)

R_5 (先生、年令)

R_6 (評価)

R_7 (学生、住所、修得単位)

(a) R_8 (講座、責任者)

R_1 (科目、単位数、平均点)

R_2 (入学年度)

R_3 (科目、先生)

R_4 (科目、学生、点数)

R_5 (先生、年令)

R_6 (評価)

R_7 (学生、住所、修得単位)

(b) R_8 (講座、責任者)

図 6 データベースの設計 (I)

する親レコードが存在する。親レコードが対応する子レコードを必ず持つ場合を*で表わしている。これは、レコードの挿入・削除の際に管理を要するものである。ここまでの結果が図6(b)である。

R_3 では、属性"科目", "先生"はそれぞれ親レコード型 R_1, R_7 の属性なので、冗長なものとなる。しかし、 R_2 では科目ごとに先生を求める質問となるので、ここで"先生"だけを除去する。同様に、 R_4 では"科目", "学生"が冗長であるか、質問 R_3 より"科目"は削除せず、"学生"のみを削除する。

次に子レコードの順序であるが、 R_1 は学生順の指定があるのを、 $\langle R_2, R_7 \rangle$ の親子集合では子レコードは"学生"の値を並べる。 R_3 は点のよいものから並ぶので $\langle R_2, R_4 \rangle$ は点数の順に子レコードを並べる。

R_6 でも成績の優秀なものから並ぶので $\langle R_1, R_4 \rangle$ も点数の順に子レコードを並べる。親子集合型で子レコードの順序を決めたいときに、何の順序によるとかを、

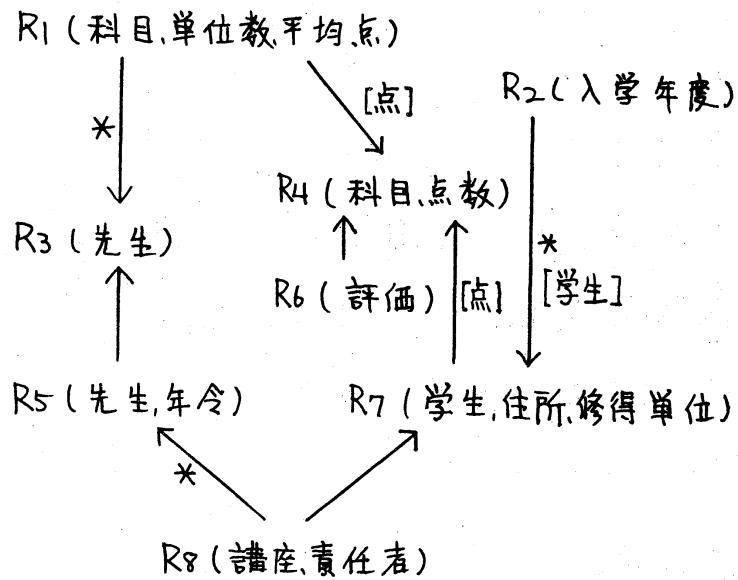


図7 データベースの設計(II)

[] で表わすと、最終結果は図 7 となる。

文献⁽⁷⁾では、例 5 では扱えなかった質問処理の効率化のための変換（索引構造の付加や親レコード型の属性を子レコード型にも持たせ等）、履歴の管理の問題を扱った例を示している。

6. あとがき

本稿では、ネットワークデータベースの設計のために、ネットワーク構造の解析を行なった。また、その結果から、実際のデータベースの設計を示した。これでネットワークモデルに対するスキーマ設計の問題点が明るかになったと思う。

謝辞

日頃、熱心に御指導、御検討いただき京都大学矢島脩三教授に深謝いたします。また、熱心に御討論いただき研究室の皆様に感謝いたします。

参考文献

- (1) 上林, Kim, 酒井編, 最近のデータベースシステムとその応

用, bit 1月号別冊, 共立出版株式会社, 1984.

- (2) Kuck,S.M., Sagiv,Y., "A Universal Relation Database System Implemented Via the Network Model", Proc. of 1st ACM Symposium on PODS, pp.147-157, March 1982.
- (3) Kuck,S.M., Sagiv,Y., "Designing Globally Consistent Network Schemas", Proc. of ACM SIGMOD Int. Conf. on Management of Data, pp.185-195, May 1983.
- (4) 古川, 上林, 矢島, "ネットワークモデルにおける意味制約", 電子通信学会オートマトンと言語研究会, AL83-43, 1983.
- (5) 上林, 古川, "関係モデル-タペース理論を用いたネットワークモデル-タペースの設計", 電子通信学会オートマトンと言語研究会, AL83-58, 1984.
- (6) Lien,Y.E., "On the Equivalence of Database Models", JACM, Vol.29, No.2, pp.333-362, April 1982.
- (7) 上林, "関係モデルによる設計と比較", 情報処理学会「データベース」シンポジウム, 1983.