

INQ (INformation Query) について。

後藤 龍男, 土居 嗣典
(日本電気株式会社)

1. はじめに。

INQ (INformation Query) は情報検索に対する効率と柔軟性を目標に開発されたDBMSである。1976年夏に最初のバージョンが市場に提供され、現在幾つかのユーザのもとで稼働している比較的新しいシステム・ソフトウェアである。

INQの機能仕様の決定はある明確な方針にもとづいて行われた。すなわち概念の体系化や理論化より利用者にとって何が現実には有用であり不便であったかという様子を視点を設計のテーマとしたことである。

元来、DBMSを利用する立場からの利害は必ずしも一致してはなく、そこから発生するDBMSに対する期待や要望を体系化し概念統一することは極めて難かしい。多くの過去のようだった努力が何かと現実から遊離しがちであったのも無理からぬことと思われろ。しかし、DBMSが真に実用的でありうるためには常に求めらるべきことの因、何が真に有用であるのかと云った問題認識が中心に置かなくてはならない。

2. INQの設計目標。

INQの設計目標は過去のデータベースシステムに関する実際経験と反省の中から取捨選択し決定された。その基本点は次の様なものである。

- ① 使用にあつたの容易性。
- ② 運用の柔軟性。
- ③ 問題に対する即応性。

2.1 容易性について。

過去にありて従来のファイル管理レベルからDBMSへの移行を試みたユーザは当初ある程度の困難を感じて来られた様に見える。その結果DBMSの効用を認識しながら導入にふみ出されたケースも少くはないであろう。その要因は多様であろうが重要なものは共通している。

それはユーザが保有する情報構造をDBMSが規定するいわゆる「データ構造」へ再編成する作業にある。ほとんどのDBMSはデータの統合化、一元管理、アクセス手段の効率化のためにデータ格納様式の構造化表現をユーザに強要する。これは縦構造であったり木構造であったりするが、ユーザにとって決して親密な概念とは云えない。その理由はデータ構造と云うもの自体がDBMSにとっての便宜であつた本来的な情報構造の表現様式ではなれないことにある。例えば階層木構造システムにおける上位セグメントと下位セグメントの階層関係や、DBMS仕様のレコードタイプ間のセット関係など、構造表現と云う観点からは簡明で強力なものであろうが、ユーザが自分の持つ情報群とその枠組で律しようとするともはや直観的に理解にもとづいて作業がはたかたする。このことがいわゆるデータベース設計を決して容易とは云えない作業にしてしまう原因になる。

データ構造は河通も考へうるし、ユーザにヒツクその内どれが最適か選択があるのが判断がつかなくなる。

ユーザにヒツク最も親密であり直観的把握の容易なデータ格納様式は旧来からの順ファイルであろうと思われ。このことからINQでは基本的なデータ格納様式として順ファイル形式を採用することと使用容易性を計る。順ファイル形式そのものはデータ構造表現とは必ずしも一致しないが、その中にデータの関連を平坦な表現で内包させ応用プログラムに提供することを試みている。

オ2はデータベース管理の統合化の問題にある。多くのDBMSはデータ管理の統合化と一元化をデータベース化の主要目的として来た。冗長なデータの存在はよからぬことであり、管理の統合化こそが進歩の要諦であると述べた。そのためにデータベース管理者の役割や権限がヒツク強調される様になる。データベース管理者はもはやデータ管理だけでなくそれを通して運用組織の管理にまで発言権を有する様な立場にまで上上げられぬばかりのヒツクありである。

この様な傾向はデータベース導入を企てるユーザにヒツク負担の大きい要請であることも多いであろう。INQではデータ管理を統合化、一元化と去う観点でとらえず、データを必要とする利用者がそれぞれ個別に作成し管理することを前提とし各種の機能を用意する。このことはデータのよほど厳密な一元化や統合管理を必要としなくなりユーザにヒツクDBMSの導入を容易なものにする。

2.2 柔軟性について。

DBMSが元来高度な多様な機能によりユーザに便宜と柔軟性を与えることを目的としているにもかかわらず、現実にはデータベース化が変化に対し適応しづらいことが多い。その最大原因はデータベースの追加/変更作業が去われる程に容易なものとはならないことである。その隘路は前項に共通するデータ構造の固定化にある。少し規模の大きいデータベースになると全体の再構成/再編成作業などよほど致命的な状況が起らぬかぎり実施する気にならざると去うのが正直な所であろう。この困難は作業に対し特別な専門家の存在を要するし、データベースの維持管理に限るかた人々のものにしてしまふ結果を生む。

INQはデータベースの中に構造を固定化してしまふことを避け、データベースに対する追加/変更の柔軟性を確保することを試みている。

前項の容易性とあわせて、INQはその使用や運用に際して特別な要請的はトレーニングや経験をよほど必要とせずデータベース化への移行キヤツプを低減させる。

2.3 即応性について。

問題(応用プログラム)がDBMSに期待するアクセス形式はある程度のデータ量にヒツク連続した処理の効率を重視する場合とある選択基準のもとでデータ検索の応答性に重きを置く場合とがある。この両者に要する機能は製造技術上は互律背反的と去える。

INQはどちらかと去うと検索指向の非定型処理に目標を置いて、その機能と処理性能の最適化を計ることとした。そのためファイルの基本的な物理構造に部分インバートインデックス形式を採用している。またエンドユーザ向けの即応性の高い言語インタフェースにも重きを置いている。

3. 機能と構造。

3.1 データベース全体の論理構造。

INQデータベースはINQファイルの集合として構成される。INQファイルはデータベース内に最大63個まで許され、データベースはシステム内に300個まで登録できる。基本となるINQファイルはそれぞれ自体が閉じた情報集合体であり、INQファイル間には何れの論理的/物理的関連をもたない。強いて関連を求めればファイル内に格納されたデータの値に依存する潜在的なものでしかない。




図3.1.1 全体構成の比較

- ① データベース拡張の容易性 --- 新たなINQファイルの追加は他のINQファイルに影響を与えない。
- ② データベース保守の柔軟性 --- INQファイル単位の破壊が他のファイルに影響しない。

統合型データベースの場合新たなレコード(ファイル)の追加は他のレコードとの関連を構造化することと意味するので、その作業は全体的なデータベース構造についての見通しが必要となる。

3.2 INQファイルの論理構造。

1個のINQファイルは1つの情報主体とその主体に属する情報群に好むと実体化される。すなわちINQファイルは主体毎に存在し、その情報群がその中に格納される。主体とは情報集合を特徴付ける集合体名に相当すると考えられる。

例えばファイル「地方自治体」は北海道、青森、岩手...と全国都道府県集合




図3.2.1

の集合体名であり、日電、東芝、日立...に対する「会社」が集合の情報主体である。そして主体の要素がINQファイル内の各論理レコードに対応しその各種の情報データとしてレコード内に格納されることになる。

1個のINQファイルは複数の主体をあらわすことにはなり。それ故、INQファイルに対する検索は主体で示される集合に対するその全要素中から条件を満足する要素(論理レコード)を選択する操作とコンピュータ上でとる。

例えば 条件; “人口800万人以上の 地方自治体は?” → 結果; 論理レコード “東京都”の選択。

多くの統合型データベースが多目的指向であるのに対し、INQファイルは上記の意味においてある1つの目的を指向した目的向きファイルであると云ふ。

INQデータベース全体として多目的であることと望む場合、各目的向きファイルであるINQファイル間にデータを重複させる結果となる。統合型システムがデータの一元化を基本的な目標にするのに反し、INQはそのことに必ずしもこだわらぬ。データベースの格納効率や無矛盾性を追求するあまりのデータの冗長性排除はデータ管理者に便宜を与えども、エンドユーザーにとってはむしろ利益ではあり。

INQファイルはその必要とするものが作成し維持することに前提を考へる。その結果異なるファイル間にデータの重複や相互矛盾がある場合でもデータベース全体の問題とはせず当事者間で解決することになる。




図3.2.1 論理レコードのフォーマット構造。

INQファイルは要素(レコード)にわたる1個のファイルに定形式である。レコードには要素に関する種々の情報がデータ項目として格納される。またレコード内構造として単一項目の他に不定繰返し(3次レベルまで)や不定繰返し(25次レベルまで)項目をもつことがある。

この様にINQファイルは(図3.2.1)に示される様なレコード内構造を有する平坦な順

ファイルとして表現される。レコード内構造としても不定/不定繰返しは階層型データベースの階層構造と等価な表現でもある。繰返しのネスタングは階層が多段であることに対応する。

通常の階層型システムにふりてもあるアプリケーションが必要とするレコード型の数と階層構造の規模はさほど大きくはなものでなく、ある程度の規模で大半の問題は充足してしまふ。INQシステムのもとではアプリケーションが必要とするデータ関連は基本的に一つのINQファイルに包含してしまふことを目標にしている。

アプリケーションが2個以上のINQファイルとその相互関係(ファイル間構造)を必要とするケースに対しINQは動的なファイル結合機能と仮想ファイルを提供する。

3.3 データ項目とその属性。

データ項目はその属性によって次の様に分類される。

データ項目の属性 --- (a) データ構造に関する属性。

単一項目 / 可変項目、
基本項目 / 配列項目 / 集団項目。

(b) データ操作に関する属性。

検索項目 / 表示項目、
仮想項目、BY項目。

(c) データ形式に関する属性。

文字型、整数型、実数型、倍精度実数型、数字型、演算符号付数字型、-----

(1) 単一項目；1つのレコードに1つ1つの値をもつデータ項目である。

(2) 可変項目；1つのレコードに1つ1つ複数個の値をもつデータ項目である。

(3) 基本項目；最小単位データに対応するデータ項目である。

(4) 配列項目；定繰返しをもつデータ項目である。

(5) 集団項目；複数個のデータ項目の総称としてのデータ項目である。

(6) 検索項目 / 表示項目；検索項目は検索キーとなるデータ項目であり、システムが項目毎にインバーテッド・インデックス（逆索引）を設ける。それに対応して表示項目はデータの表示だけに用いられる項目であり、逆索引が設けられることはない。

INQシステムでは検索キーとして用いられる可能性がある全てのデータ項目は検索項目として扱われ、その数に制限はない。検索キーとなる可能性のない項目についてはだけ表示項目であることを陽に宣言し、逆索引に要する二次記憶スペースを節約する。いわゆる部分インバーテッド・インデックス・システムである。

(7) 仮想項目；その値が他のデータ項目の値や構造情報により決定される項目でありその値自身は実際にデータベース中に格納されない。値の決定方法は、INQファイル定義時にあわせて定義する。その値の管理はシステムが行なう。決定方法は次の4通りである。

① 計算式 --- データ項目、定数、四則演算子、カッコで表現する計算式にもとづく。

② 合計値 --- 可変項目の値の合計値による。(TOTAL)

③ 合計数 --- 可変項目の繰返し数を値とする。(COUNT)

④ 平均値 --- 可変項目の平均値による。(MEAN)

(8) BY項目；複合条件検索における限定(Qualification)を指定された項目である。

一般に階層構造に対する条件検索において複合条件の意味にある種のありまじりを含む場合がある。例えば下図に示される様な構造に対する条件「製品としてカラーテレビも、売上額が1億円以上の会社」は次の様な2通りの意味にとれる。

① カラーテレビの売上げ額が1億円以上の会社。

② 全製品の売上げが1億円以上の会社。




図3-3-1 階層構造。

前者の様に階層下位の項目にフリの条件で上位の条件を限定するためには、検索言語自体に限定機能が必要となる。INQでは下位の繰返し項目に対する条件により限定された場合、これをBY項目として定義しておく。

BY項目と指定した場合、BY項目(製品)と被BY項目(限定している項目すなわち売上額)はフリのそれぞれの各々の逆索引の間に階層関係が作られる。

3.4 INQセクション記述と仮想INQファイル。

INQデータベースは個々の実INQファイルを記述するデータ定義言語(FDL)によって定義される。これは別の応用プログラムに対しては別の記述であるINQセクション記述を与えている。INQセクション記述は実データベースの応用プログラムにとって必要な部分を仮想的なファイルとして表現するものである。

INQセクションは大別して2通りのファイル仮想化を行う性格をもつ。

- ① INQファイル及構造のサブセット化。
- ② 異なった2以上のINQファイル間構造の具体化。




図 3.4.1 INQセクションと仮想ファイル。

FDL記述とINQセクション記述の概念はDBTG仕様におけるスキーマ/サブスキーマの階層に類似しているが、次の点で本質的に異なっている。すなわち、サブスキーマがデータベース全体記述であるスキーマの単純なサブセット化(部分の切り出し)であるのに対し、INQセクションはINQファイルのサブセット化のみならず複数のINQファイル間新たなファイル間構造を設定して新たなINQファイル(仮想INQファイル)を生成する機能をもつ。

DBTG仕様を代表とする統合型システムでは、データ構造(特にレコード間構造)はあらかじめ固定的に具体化せざるを得ず、問題毎に必要な構造を最適化することは不可能であった。データ構造の問題適合性にかたまりが生ずることを避けられず。これは統合型システムでのデータベースの存在の仕方がセットなどのレコード間構造によることによる。

INQではINQファイルは互に独立に存在するものであり、ファイル間の関係は応用プログラムが必要とする時点で具体化される。つまり問題毎に最適化された構造がINQセクション記述で提供される。

INQセクション記述の実データベース(FDL記述)への写像はシステムが管理する。応用プログラムに見えるのは仮想INQファイルA', B'(図3.4.1)であり、両記述の距離によるデータとプログラム間の高い独立性が確保される。

3.5 ファイル結合

前項に述べたINQセクション記述の内、INQファイル間構造の生成機能を“結合”とよんでいる。2個のINQファイルの結合はDBTG仕様のセット関係ほどのレコード間構造とはほぼ等価であるが、次の2点でそれらとは本質的に相異がある。

- ①結合関係はあらかじめデータベース内に構造化される必要はない。
- ②結合はファイル間構造として応用プログラムに見せることはなく、一般的にINQファイルと同じレコード間構造をもつ新たなINQファイル(仮想INQファイル)として提示される。プログラムは結合を何と意識する必要はない。結合は2個の独立したINQファイル同士で意味的に共通したデータ項目に着目して行われる。

図3.5.1は会社ファイルと製品ファイルの間に「製品名」というデータ項目にフック結合した例を示している。




図3.5.1 ファイルの結合。

会社ファイルと製品ファイルはINQファイルとしてデータベース内に実在するが、結合結果の新たな“会社-製品ファイル”は仮想INQファイルである。

結合操作は階属上位のINQファイルの中に下位のファイルを経過しとして反包させてしまうことに相当する。この様にINQでは応用プログラムに好ましくあっても平準なファイルを提供する。

結合の対象となる項目(製品)は特定の構造属性を要求できる、応用プログラムにとって意味があれば何であってよい。データ値のみに関する操作である。

1つのINQセクション内で最高4個までのINQファイルを結合することはできる。

一般的に結合(ファイル間構造の実体化)の手法には次の3通りが考えられ、それぞれ長短がある。

- ① レコード自体に結合のための写像情報(ポインタなど)をもたせる。結合は固定される柔軟性は低いが処理効率が高い。
- ② 写像情報をレコードとは別に保有する。写像情報を変更すれば結合も変えられるが、レコード内容の変更は写像情報の更新も必要になる。
- ③ 写像情報をもたず結合操作を何らかの写像アルゴリズムとして実現する。結合は固定されず動的に設定しうる。レコード内の値の変更自体が写像情報の変更に対応する場合になる。

INQシステムの結合はこの3つの方法にまつている。この選択の最大の理由は柔軟性とデータベース管理の簡易化にある。反面結合ファイルに参照する場合プログラム手続による写像処理をともなうので処理効率に比べて有利な選択ではない。このトレードオフは次の根拠にまつている。すなわち、問題(応用プログラム)が必要とする情報は1つのINQファイルの範囲で完結するべきであり、また大半の問題はそれだけで充足するはずである。1個のINQファイルでは済まぬ比較的小さな問題に対しては結合が適用されるが、その場合処理効率はそれほど重要でない。(重要視する様な頻度の高い処理対象であるなら、はじめから拡張したINQファイルを持つべきである。)

このようなアルゴリズムによるファイル内構造の実現手法は、将来分散型データベース環境を想定した場合、物理的に離れて置かれた2つのファイル間の関係もデータベースプロセスに対し実体化し提供するための手段となる可能性をもつ。

3.6 INQファイルの物理構造。

INQファイルの物理構造は部分インバーテッドインデックス形式にまつている。INQファイルの格納される物理的記憶空間は一定の大きさのページにまつり構成され、ページ単位の入出力制御にまつり入出力効率を高めまつる。INQファイルは次の3つの部分で構成される。

- ① ディスクリフタ部 ----- INQファイルの論理的構成要素であるデータ項目属性情報やデータ項目間の構造情報が格納される。
- ② インデックス部 ----- 検索項目毎の逆索引が格納される。(図3.6.1)
- ③ 実データ部 ----- レコードの各データ項目の値が格納される。レコードは一貫のレコード番号(RN)をもつ。(図3.6.2)




図3.6.1 インデックス部の構造。

3.7 検索とその操作言語。

INQは基本的なデータ操作言語として親言語方式のDMLをもつ。その中の検索機能(RETRIEVE)のレコード選択基準は論理式からなる複合条件にもとづく。条件式は図3.7.1の様な比較オペレータ, 論理演算オペレータにより記述される。

次の様な複合条件式にもとづく検索を考へる。

"名前" = サトウ AND "年令" > 30才

検索操作は"名前"と"年令"の2つのデータ項目のインデックスを独立に参照し条件を満たす2つのレコードの集合が選択される。



この集合は実データではなく2進表現によるレコード番号(RN)の集合である。論理演算オペレータで表現された複合条件の操作はこのレコード番号集合間の集合演算に置きかえられる。

レコード番号群はその値が異なる位置のビットを1としたビットストリングに変換しストリング間の2進演算操作に置き変えられる。この値は図3.7.2の様なる階層から成る論理演算用テーブルの対応ビットにセットされ、このテ-

機能	オペレータ
一致	= EQ
近似的一致	:= NR
不一致	≠ NE
より大	> GT
より大, 一致	≥ GE
より小	< LT
より小, 一致	≤ LE

機能	オペレータ
論理和	OR
論理積	AND
否定	NOT
演算順	()

図3.7.1



ブル間で論理積の処理が行われる。処理は最上位テーブルから順に演算が行われるので、不必要な下位テーブルのアクセスが省略でき高速化が計られる。

複雑な条件検索も操作は全てインデックス部と論理演算テーブルのみで行われ実データを参照することなく極めて高速な応答が実現できる。

3.8 データの圧縮と暗号化。

インバート方式の難点はデータ格納効率の問題がある。INQはデータ格納時の圧縮でこの問題を実質的に解消している。データ値はその属性が文字タイプの場合は指定された文字(デフォルトはブランク)で、浮点数字タイプの場合はそれが整数型, 実数型の場合を除いて, 先行する0が省略されサプレスされてバックドシマルの形式で格納される。

またデータ格納時にユーザの指定によりデータを暗号化し格納することもできる。

4. INQの構成

INQシステム全体は図4. の様な要素から構成される。この内言語インタフェースは2種のデータ定義言語(FDL, INQセクション)と3種のデータ操作言語(DML, RPL, EUL)およびデータ管理用言語(DSL)を用意している。INQセクション記述はDMLはホスト言語に依存するが他は独立言語である。EULは非プログラマ向けの言語インタフェースであり、TS端末からの会話型の検索とデータ加工処理を目的にするものである。

INQはACOSシリーズの大型機種であるNEACシステム600, 700, 800, 900とそのオペレーティングシステムACOS-6のもとで実行される。

5. その他の特徴的機能。

- (1) データベースにとって重要な機能である検索保護に付しては前述したデータの暗号化と項目毎に設定できる20レベルのパスワード機能が用意される。
- (2) INQの重要な応用システムとして文章情報の処理を想定し、各種の便宜を計っている。文章情報の格納形式には単語単位と不定繰返し項目に収容する方法が有効である。データ圧縮は漢字コードを想定して2文字単位の処理も行う。




図4. INQの全体構成。

6. あとがき。

最近関係モデルに関する議論が盛んである。INQの利用を結果として見ると種々の異なった関係モデルに似ている様に感じる。INQファイルの平坦な「関係」に当り、結合はJのIN操作に似ているし、検索処理を集合演算で表現する事も共通している様に思える。しかし基本思想は全く異質であると云って宜い。すなわち関係モデルではデータ集合としての「関係」に完全に論理的な演算操作によって対応していることが要求されるため、「関係の正規化」が不可欠であることである。結果として情報集合は沢山の全く平坦な「関係」に分割されてしまう。関係データベースの利用者はその沢山の「関係」を認識してかからねばならないであろう。これはまた別のやりかたをまねくことにもなりかねないと思える。

〔参考文献〕

- INQ概説書
- 文法説明書
- 運用説明書
- エンドユーザ言語説明書