

人名に付属する多數のアトリビュート毎の仮想 ランダム・ファイルを同時に OPEN できる知識系

(株) 佐々木機械事務所 佐々木 機
(株) エー・ピー・アイ 有水 草
(株) ジャパン・コミュニケーション・インスティテュート
若槻 史郎、吉田 等

1. 概要

パーソナル・コンピューター PC-9800 に高速のマーク・カード・リーダを接続し、マーク並びにキー入力により人名に付属するアトリビュート(住所、生年月日、-----)を128個入力した上知識を行なうシステムを開発した。

128個のアトリビュートのうち30個はマーク・カードから直接読み取り、残り9個はキーボード、残りの9個はマークから値を計算する様になつてゐる。

知識は1000個までの人の名とそれに付属するアトリビュートの登録と、複数のアトリビュートの値に関する論理的な條件が成り立つて人名の抽出、並びにその人名に付属する住所などを印字出力が主な内容である。

アトリビュートの値に関する論理的な條件としては、30個までのアトリビュートに關して

アトリビュート $m = \text{ある範囲}$ AND アトリビュート $n = \text{ある範囲}$ AND
 \dots

を指定して検索/抽出を行なう事ができる様になつてゐる。図1にユーザーによる検索の具体例を示す。

本システムの特徴は、アトリビュートの格納方式の工夫により図1の様な検索が高速である事と、マーク・カード・リーダのインターフェースの工夫により図2の様なマークでも設まりやすく読み取れる事であるが、ここではアトリビュートの格納方式と検索のスピードについて報告する。

本システムで採用したアトリビュートの格納方式とアクセスの方式により、プログラムの「業務知識部」には各アトリビュートがそれぞれ独立の仮想ランダム・ファイルに格納されていて、かつこれらのファイルが全て OPEN の状態と見做され、1000名分の12万8000個の独立したデータにランダム・アクセスを行なう事ができる。

シ"ヨウケン / シティ

1. セイホン = 年
 2. タンシ"ヨウヒ" = 月 日
 3. ホンタ"イ" = 3
4. セイヘ"ツ" = 1
 5. カソ"ク コウセイ" >
 6. オキヤクサマ =
7. オスマイ =
 8. セタイ =
 9. ショクキ"ヨウ" =
10. シュミ =
 11. テイキ・コート" =
 12. コキヤフ フ"ンルイ" =
13. ショユウ ヒン =
14. オカイアケ" () = 年 月 イゼン
 15. 21セイキ テスト () >
 16. ハイテック" () >
17. コウニユウ ミヨミト" () >
 18. シ"ヨウケン イコウ / ミヨミ () ... (Y/N)
19. ホウジ"ヨウイト"、ソノタ () >
 20. ハシ"ヨウケン(センフ)" ... (Y/N)

コレラ / シ"ヨウケン ヲ ミタス オキヤクサマ ハ、8メイ サマ テ"ス！

1. OK 2. サラニ シ"ヨウケン ヲ シティ.....ハシコ"ウ=(

図1. ユーティによる検索の具体例。性別がエ(男)で年齢が3歳の
人の名前が複数ある事を表示している。

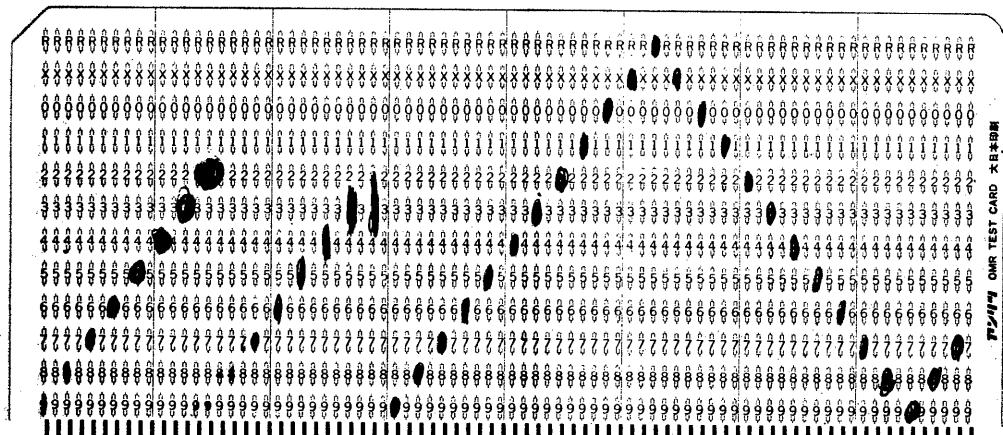


図2. 本システムで読み取れたマークの例(一番ひどいマークト外は正しく読み取れ事がある)

2. 本システムの必要性

パーソナル・コンピュータではフロッピ・ディスクにデータを格納するのにシーケンシャル・ファイルとランダム・ファイルを使用する事ができるが、本システムの様に不特定多数のデータの照合/検索を行なう場合にはランダム・ファイルを使用しなければならない。しかし、次の様な問題があるため、人名並びにそれに付随する各アトリビュートを單純なランダム・ファイルに格納して物理的な事は現実的ではない。

すなわち、PC-9800で8インチ(2D)のフロッピ・ディスクを使用する場合にハマリえば、ディレクトリのエントリは最大151個、同時にオープンできるファイルは15個までであり、ディスク上のエリアの割当は1トラック=26セクタ=6656Bをその単位とし、ディスクとプログランクの間のオフセットは256B(固定)のレコードを単位とする様になっている。

この事は、プログラン上での同時に使用できるファイルは15個までであり、あるファイルの内容がたまたま1Bであることをディスク上で他のファイルがユートラックを占有する事を意味する。

本システムでは1000個の人名(16B)に付随する各アトリビュートが例えば住所(60B)、特定の商品の所持の有無(1B)などのように、それぞれのバイト長が異なるので、上記の様なファイル・システムでは専用の方システムを作りするのが困難である。

この問題に対処するため、本システムでは図3に示す様にデータ格納用にディスク全面を占有する "DATA" という1MBのデータ・ファイルを用い、"DATA" のエリアを128個のアトリビュートの格納用に分割して使用している。

FILES 2

| | |
|------|-----|
| DATA | 151 |
| Ok | |

図3. 本システムではただ1個のデータ・ファイル "DATA" のエリアを分割してアトリビュートを格納してある。

従って、特定のアトリビュートのN番目($N = 1 \sim 1000$)のエントリにアクセスするためにはその度毎に "DATA" 内における格納場所(レコード番号とバイト位置)を計算してある。

本システムにおいてはこのマッピングも BASIC で書かれており、業務処理部から見えてる様に見える。

この様なマッピングを BASIC で書くを実用上差支えなしといふ事は

重要な事実であり、この事とマッピングの具体的な方法、並びにシステムとして実現した性能がこの報告の骨子である。

3. 本システムの仮想ランダム・ファイル

上述の様に本システムでは "DATA" というただ1個のランダム・ファイル上のエントリを分割して128個のそれぞれ長さが異なるアトリビュートの格納に用い、アクセスの度毎に格納場所を計算している。そして、「業務管理部分」からはこのマッピングが見えておられる。

具体的には、例えは $VR \% = 325: GOSUB *R.ADR: PRINT INF$$ という処理により、2325番目の人名と付属する住所をCRTの画面に表示される（ $VR \%$ は Virtual Record の番号を表示する変数）。

書き込みの時に、 $VR \% = 325: INF\$ = "ヨコハマ シ.....": GOSUB *W.ADR:$ により2325番目の住所の所に文字列を書く事ができる。

R は Read、 W は Write である。INF\$ は Information 拡張用の変数である。

"DATA" 自体はランダム・ファイルであるが、上記の様な Read/Write も具体的にはランダム・ファイルのレコードの R/W の実行であり、「業務管理部分」では各アトリビュート毎に専用のランダム・ファイルがあり、そのエントリはアクセスしてハンドリングしロッピ・ディスクを使用する事ができる。

これが本システムの仮想ランダム・ファイルの意味で、プログラム起動時に $OPEN "Z: DATA" AS #1$ を実行するのみで個々の仮想ランダム・ファイルの OPEN/CLOSE は不要であり、この事も実用上大きな便益となる。

本システムの各レコードは人名とそれに付属するアトリビュート全体の集合であるが、各アトリビュートが "DATA" 内で分散格納されている様子を図4に示す。

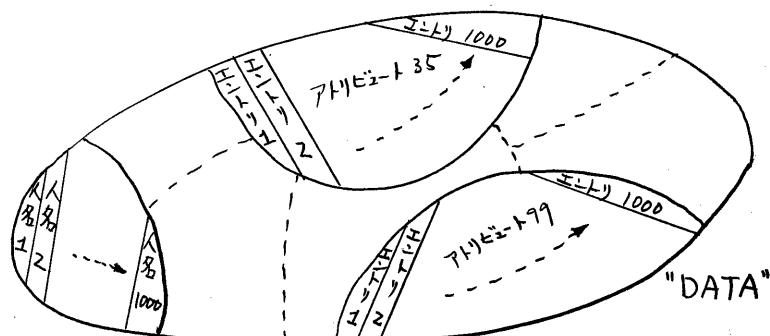


図4. 各アトリビュートの "DATA" 内の格納状態

4. マッピングとアトリビュートへのアクセスの詳細

本リストでは各アトリビュートを "DATA" 内に分散して格納している。事は上記の通りであるが、例えば電話番号はレコード52から1エントリ毎に2Bを割り当てる1000個を格納する様になっている。

アクセスの具体的な方法は、例えば「3番目の電話番号として "123-456-7890"」を書いた後で読み出してCRTに表示して見る処理は図5の通りである。

```
VR% = 433: INF$ = "123-456-7890": GOSUB *W.TEL... カンコミ
VR% = 433: GOSUB *R.TEL: PRINT INF$... ヨミダシ
END

50260 *MAP.TEL
50270 PR% = 52 + (VR%-1) % 21: N1% = 12 * ((VR%-1) MOD 21): N2% = 12: RETURN
50730
50740 *ACCESS .
50750 FIELD #2, N1% AS DUMMY$, N2% AS DD$: GET #2, PR%: RETURN
50760
50770 *WDISK
50780 GOSUB *ACCESS: LSET DD$=INF$: PUT #2, PR%: RETURN
50790
50800 *RDISK
50810 GOSUB *ACCESS: INF$=DD$: RETURN
50820
51080 *W.TEL
51090 GOSUB *MAP.TEL: GOSUB *WDISK: RETURN
51680 *R.TEL
51690 GOSUB *MAP.TEL: GOSUB *RDISK: RETURN
```

図5. "DATA" のレコード52から始まる格納領域内の電話番号にアクセスする処理

上のリスト中 VR% は前述の通り Virtual Record の番号を表示する変数であり、 PR% は Physical Record ("DATA" のレコード) の番号を表示する変数である。

サブルーチン *MAP.TEL が電話番号に関するマップングの計算である。図6にその意味を示す。

図5と図6は本リストで行なってあるマップングの一例を示すものであるが、一般には次の様にしてマップングを行なえばよい。

$$PR\% = \text{先頭物理レコード番号} + (VR\%-1) \% (\text{最大データ収容個数}/\text{レコード})$$
$$N1\% = \text{データ長} * ((VR\%-1) \text{ MOD } (\text{最大データ収容個数}/\text{レコード}))$$

この様なマップングを行なう場合、一般に "DATA" のレコードを

より 256 B はデータ長の整数倍であるから、各レコードの終りに無駄が生ずる。マッピングの形を更に工夫してこの無駄をなくすことは可能であるが、実用上の便益は左程大きくないと思われる。

| | VR% | PR% | N1% | N1% |
|----|-----|-----|-----|-----|
| 1 | 52 | 0 | 12 | |
| 2 | 52 | 12 | 12 | |
| 3 | 52 | 24 | 12 | |
| 4 | 52 | 36 | 12 | |
| 5 | 52 | 48 | 12 | |
| 6 | 52 | 60 | 12 | |
| 7 | 52 | 72 | 12 | |
| 8 | 52 | 84 | 12 | |
| 9 | 52 | 96 | 12 | |
| 10 | 52 | 108 | 12 | |
| 11 | 52 | 120 | 12 | |
| 12 | 52 | 132 | 12 | |
| 13 | 52 | 144 | 12 | |
| 14 | 52 | 156 | 12 | |
| 15 | 52 | 168 | 12 | |
| 16 | 52 | 180 | 12 | |
| 17 | 52 | 192 | 12 | |
| 18 | 52 | 204 | 12 | |
| 19 | 52 | 216 | 12 | |
| 20 | 52 | 228 | 12 | |
| 21 | 52 | 240 | 12 | |
| 22 | 53 | 0 | 12 | |
| 23 | 53 | 12 | 12 | |
| 24 | 53 | 24 | 12 | |
| 25 | 53 | 36 | 12 | |
| 26 | 53 | 48 | 12 | |
| 27 | 53 | 60 | 12 | |
| 28 | 53 | 72 | 12 | |
| 29 | 53 | 84 | 12 | |
| 30 | 53 | 96 | 12 | |

図6 マッピングの計算ルーチン *MAP. TEL の処理

本システムでは前述の様に特定のアトリビュートの値がある範囲に入っている人名を抽出する事が主要な機能となつてゐるが、そのアトリビュートの値を上書きのエントリから1000 番目のエントリまで、しらみつぶしに調べなければならぬ。

人名のみであればハッシュングなどの手法も使之るが、他のアトリビュートは端から調べて行かなければならず、システム全体としての処理速度はこの事により上限が抑えられる。

そしてその際に決定的要素はあるアトリビュート 1000 個の値を調べるのに "DATA" のレコードへのアクセスが何回必要かといふ事である。

本システムでは例えば人名(16 B)は "DATA" の 1 レコード当り 16 個格納されてゐるが、"SASAKI AKIO" が登録済みか否かを 1000 個の人名をしらみつぶしに調べる場合のデータベースの所要回

数は1/16となる。

更に、大多数を占めるエニトリガーボのアトリビュートでは僅か4回のループを翻ぐのみで照合/検索が終了する。

この事が本システムにおいて処理速度の大幅な向上が実現した基本的な理由である。

5. 実現した性能

上述の様な工夫の結果、本システムでは1000個の人名のチェックが25秒、アトリビュート1000個のチェックが35~90秒で終了する。

本システムの開発は1983年6月に終了し、現在既に全国各地で实用に供されている。

6. 謝辞

本システムの開発には多くの方が色々の立場で協力された。これらの方々に心からの謝意を表す。