

文献情報検索システム A I R

篠原 武 (Takeshi Shinohara)

二村祥一 (Shooichi Futamura)

松尾文碩 (Fumihiro Matsuo)

(九州大学大型計算機センター)

1. はじめに

情報検索 (information retrieval) は、自然言語で書かれた情報を扱うところに本質がある。その情報に対する検索機構として、とくに大量の文献データを扱うときは、現在のところキーワードの転置索引 (inverted index) 以上のものがなく、したがって検索結果は近似的で正確さに欠ける。しかし、これに代わる機構が近い将来に実用化される見込みはない。反面、この技術の停滞によって、文献情報検索は安定した技術のような印象を与えており、それはまた定型的処理であるかのような誤解を招いている。

著者らは、以上のような認識の上に立って、文献情報検索システム A I R (Augmented Information Retrieval system) を開発している。A I R 第一版はディスク領域効率と検索効率を重視して設計・実現したもので、現在これを用いて I N S P E C テープのオンライン検索サービスを行っている。A I R 第一版では、自然言語情報に対する検索機能自体は従来の情報検索システムの

水準と大差ないが、ディスク使用量は3.5分の1以下、検索処理速度は10倍以上高速であり、その効率は非常に優れている。

2. 開発の背景と設計方針

九州大学大型計算機センター（以下、"九大センター"と略す）では、1979年から富士通会話型情報検索システムFAIRS-I [1]によって、INSPECテープ [2] の検索サービスを行ってきた。それは、かなりの数の利用者にとって、研究を遂行するうえで不可欠のものになっている。しかし、2次文献検索は大量のディスク領域を必要とする以外にも、システム維持のために大量の計算時間を必要とし、これらは九大センターにとって少なからぬ負担になっていた。FAIRS-Iは、多くの情報検索システム同様、キーワードの転置ファイルを作る型のシステムである。ところで、大量文献データに対するキーワードの選択は、自然言語情報の単語から不要語（stop words）を除去する以外に実用に耐える方法がない。キーワードを選択する対象から抄録を除外すると、不要語除去のための計算及び転置ファイルのディスク領域にかかる負担はかなり軽減される。しかし、情報検索システムとは自然言語情報を扱うシステムであるとの見方からすれば、2次文献中最も豊富な情報を含んでいる抄録からのキーワードを転置ファイルに入れることは、情報検索の質を著しく損なうことになるであろう。

以上のような背景から、AIRの設計に当り、つきの2点に第一の目標を置いた。

- (1) 良質の文献情報検索サービスの継続ができるだけ軽い負担で可能にする効率の高い検索システムを実現する。
- (2) (1)の"良質"とは、情報検索では自然言語情報に対する検索能力に対する評価である。キーワードの転置索引による検索には限界があることは明らかなので、必要なときには検索時に直接文章データを"

読む”機能を充実させる。

(2) の機能として、将来は自然言語理解機構を開発し、文章データを“理解”できるシステムにする計画であるが、A I R第一版ではパターン照合機械〔3〕による文字列探索程度にとどめる。したがって、第一版では、効率に重点を置いたシステム設計を行った。情報検索システムの効率はそのファイル構成によって決まる。ここでは、2次文献などの文書情報を格納したファイルを文書ファイルと呼び、文書ファイルに対する索引を格納したファイルを転置ファイルと呼ぶことにする。以下、この節ではこれらのファイルについての設計方針を述べる。

2. 1 文書ファイルのデータ圧縮

筆者らは、Q O C [4]と名付けた単語を要素とするデータ圧縮技法を考案した。Q O Cは、理論的にはZ i p fの法則が成立するすべての言語に対して97.21%という高い圧縮効率を有し、文書データを1/4以下に圧縮する。Q O Cは、最適符号ではないが、H u f f m a n 符号に比べると符号器と復号器の実行速度の点で決定的に勝っている。

I N S P E Cの抄録における単語の生起頻度特性はほぼZ i p fの法則に従っており〔5〕、Q O Cは抄録、標題などの項目を1/4に圧縮する。2次文献データ中には、Q O Cに適さない項目があり、これらを文字単位で圧縮すると、I N S P E Cテープに関しては全体として圧縮率は3.6程度となる〔6〕。I N S P E Cテープのような大量の文献情報を取り扱う場合には、文書ファイルの大きさを1/3.6に圧縮することによる利益は非常に大きい。また、A I Rのようなオンライン検索システムでは、復号器の実行速度が重要であるが、F A C O M M-382上では復号器は725ナノ秒/字の速度で走るので、Q O Cを採用しても検索結果の出力に及ぼす影響は全くないと言ってもよい。そこで、A I RではQ O Cなどの圧縮技法によって文書ファイルを圧縮することにした。

2. 2 転置ファイルと不要語選択方式

A I Rの転置ファイル、すなわち文書ファイルに対する索引は、キーワード転置ファイルと属性転置ファイルから成る。前者は、抄録、標題などからのキーワードを索引の見出し語とする。後者は、文献に対する属性、たとえば著者、雑誌などについての索引であり、見出し語は、著者名、誌名などである。属性転置ファイルは、本質的に通常のデータベース・システムの転置ファイルと同じであり、文献情報検索ではこの部分の構造はそれほど効率に影響を与えないと思われるため、A I RではこれをB木に基づく標準的な索引技法によって実現することにした。

キーワード転置ファイルの設計にあたっては、まずキーワード索引の対象について考慮しなければならない。キーワードを抽出する項目としては、標題、自由索引句、抄録が考えられるが、抄録を索引の対象とすると、キーワード転置ファイルが非常に大きくなる。しかし、最も多くの情報を含んでいる抄録を索引の対象から外すことは好ましくない。すでに筆者らが開発した不要語選択方式〔7〕によれば、検索の質をそれほど落とすことなく、キーワード転置ファイルの大きさを約半分にできる。この不要語選択方式は、自由索引句と抄録における単語の生起頻度の比を指標とするもので、自由索引句にはあまり現われず抄録に多く現われる単語が不要語とされる。

さらに、キーワード転置ファイルの設計において問題となるのは、転置ファイルで隣接演算 (adjacent operation) 〔8〕を行うかどうか、すなわちキーワードの生起位置情報を転置ファイル内に持つかどうかである。著者らのI N S P E Cテープについての調査では、生起位置情報を持つ場合、ファイルの大きさは80%増加する。また、生起位置情報を持たない転置ファイルの場合、句による検索を、句を構成する単語を含む文献集合の積で近似すると、質の悪化は検索結果が平均3倍増加するという形で現われる〔9〕。自然言語文にお

ける単語の順序が持つ情報量の大きさ、ならびに情報検索の評価としては精度 (precision) より再現率 (recall) の方が重要であることなどを考えれば、この 3 倍という数字はそれほど悪いものではないと思われる。そこで、AIR では隣接演算は、転置ファイルでは行わないこととし、必要なときには、パターン照合機械によって文書ファイルの順探索を行うこととした。

キーワード転置ファイルの索引部には QOC [10] を採用した。これは、根 (root) と葉 (leaf) からなる多岐平衡木であり、一般に根と葉の大きさは異なる。これに QOC の符号表を高頻度単語の索引としても使えるように拡張することにより、1 単語検索に要する索引部の平均ディスクアクセス回数を 0.05 回程度にすることができる。

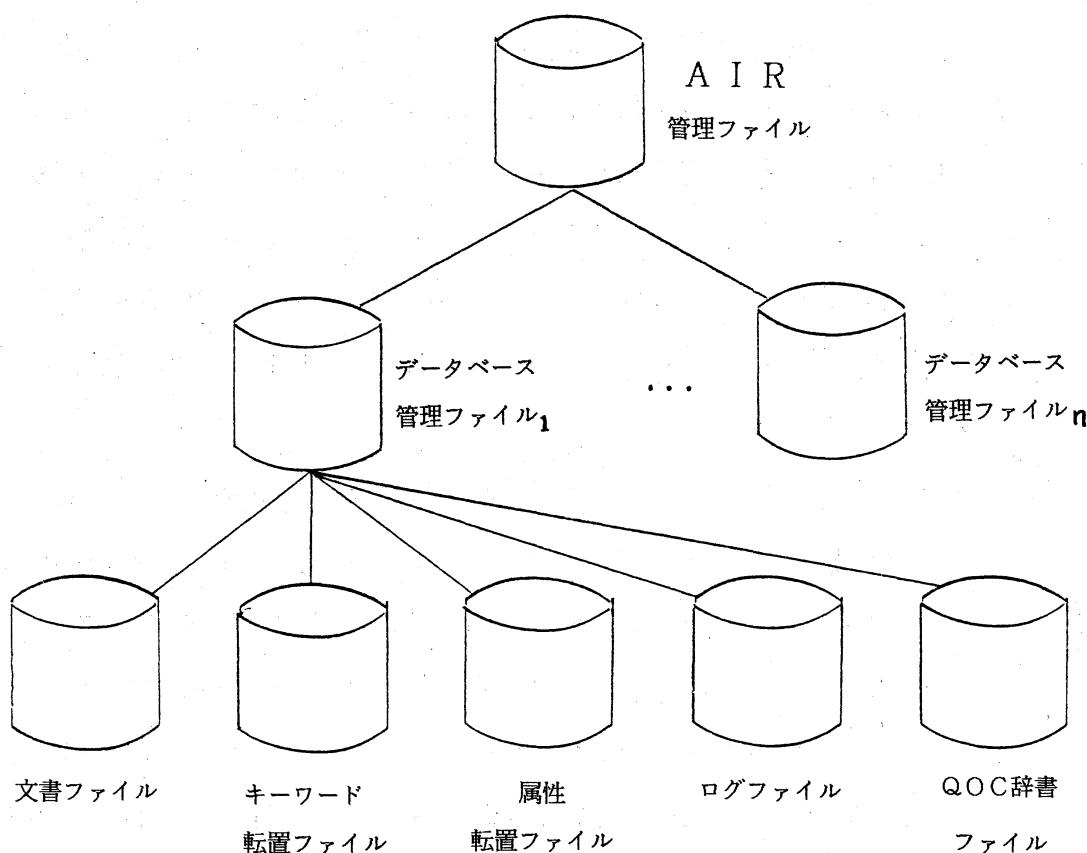


図 1. AIR のファイル構成

3. A I R の ファイル構成

A I R の ファイル構成を図1に示す。A I R では、検索対象の単位をデータベースと呼ぶ。A I R の情報検索者は、ある時点では一つのデータベースだけを利用できる。データベースは、文書ファイル、キーワード転置ファイル、属性転置ファイル、Q O C 辞書ファイル、ログファイルから構成される。Q O C 辞書ファイルは文書ファイルの圧縮を行うために必要な辞書である。これらのファイルの所在やデータベースにあるレコードの件数等はデータベース管理ファイルにある。データベース管理ファイルは、このほかレコードを構成する項目の定義情報（項目名、符号化法、転置ファイル作成の有無、出力の指示など）やデータベースの機密保護情報をもっている。データベース管理ファイルの所在情報はA I R 管理ファイルにある。

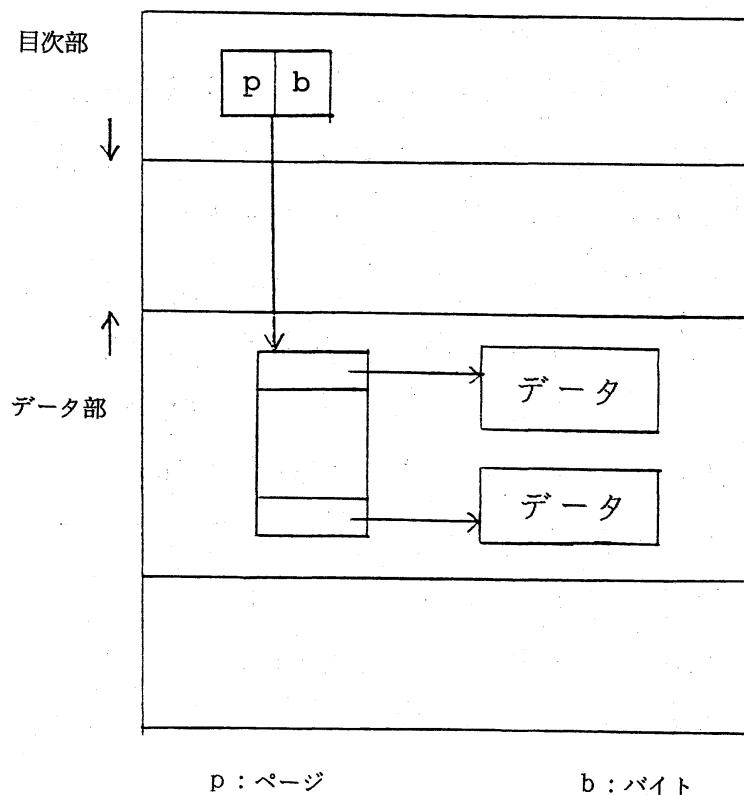


図2. 文書ファイルのデータ構造

3. 1 文書ファイルのデータ構造

文書ファイルは1個あるいは複数のデータセットから構成される。文書ファイルのレコードには、各レコードを一意に識別するために1から順に参照番号（24ビット；最大16,777,215までを管理）が与えられる。各データセットにはある範囲の参照番号のレコードが入れられる。どのデータセットにどの範囲の参照番号のレコードがあるかは、データベース管理ファイルに記録されている。文書ファイルを構成する各データセットは、データ部及びその目次部に分けられる（図2参照）。データ部には、符号化された圧縮レコードが、レコードを構成する項目の索引とともにに入れられる。目次部には、圧縮レコードの格納番地（ページ番号、先頭バイト位置の組；それぞれ2バイト）が設定され、参照番号が与えられた場合に、2回以下のディスク参照で該当レコードを見つけることができる。

3. 2 転置ファイルのデータ構造

キーワード転置ファイルには標題、抄録などの文章情報の項目から不要語フィルタを通して得られたキーワードが、その生起情報（参照番号、項目番号）とともに記録される。図3にキーワード転置ファイルのデータ構造を示す。キーワード転置ファイルは索引部とデータ部からなり、索引部にはキーワードとその関連情報（該当文献数、データ部へのポインタ；計7バイト），データ部にはキーワードの生起情報（項目番号、参照番号の組のリスト；計 $4 \times n$ バイト）が設定される。

索引部には高さ1の多岐平衡木であるQ木を採用した。Q木の根は常に主記憶に置かれて処理される。Q木の葉へのアクセスには1回のディスク参照を必要とするが、この部分にQOCの符号表（生起頻度の高い8191単語が登録されている）を併用することにより処理の高速化を図っている。

データ部の要素は、項目番号（8ビット）、文献番号（24ビット）

キーワード転置ファイル（索引部）

x	y	q ₁	q ₂	...	q _i	...	q _m	/		w	n	p	b	w	
---	---	----------------	----------------	-----	----------------	-----	----------------	---	--	---	---	---	---	---	--

↑
x ↑
y ↑
q_i

n: 文献数

p: ページポインタ

b: 先頭バイト位置

w: キーワード

キーワード転置ファイル（データ部）

p ページ:

	p'	b'	n _s	n _u	t ₁	r ₁	t ₂	r ₂	...	t _{n_s}	r _{n_s}	
--	----	----	----------------	----------------	----------------	----------------	----------------	----------------	-----	----------------------------	----------------------------	--

p' ページ:

↑
b

	0	0	n _s	n _u	t ₁	r ₁	...	t _{n_u}	r _{n_u}	/	
--	---	---	----------------	----------------	----------------	----------------	-----	----------------------------	----------------------------	---	--

↑
b'

t: 項目番号

r: 参照番号

図3. キーワード転置ファイルのデータ構造

の対で構成される。項目番号の各ビットによって項目が指定される。したがって、最大8項目までのキーワード転置ファイルの作成を指示できる。転置データはリストとして、データ部の各ページの連続領域に置かれる。ページサイズを超える場合には、ページポインタを使って、さらに次の連続領域が割り当てられる。ディスク参照回数を減少し効率を上げるため、データ部のページサイズはディスクのトラックサイズに一致させている。また、転置データの追加による効率の低下を防ぐため、データ部には創成時に、各キーワードに対してその出現頻度に応じた空領域が自動的にとられる。

キーワードが与えられ、転置データを取り出すのに必要なディスク参照回数は、転置データの最初の部分に対しては1~2回であり、残りの

部分についてはページの境界で1回ずつ必要である。

属性転置ファイルには項目の値そのものを登録する。属性転置ファイルは項目別に作成され、それは一つのデータセットにまとめて入れられる。属性転置ファイルは索引部とデータ部からなる。索引部にはB木を採用した。データ部は、キーワード転置ファイルのデータ部と同様のものである。

4. AIRによるINSPECデータベースの構築

AIRにより、1973年以降のINSPECテープからデータベースを構築した。INSPECテープの各文献は、A(物理学), B(電気・電子工学), C(計算機・制御工学)の3つの分野に分類できる。それぞれに対応してINSPECA(約110万件), INSPECB(約57万件), INSPECC(約37万件)の3個のデータベースを作成した。複数の分野に属する文献が約20%あり、ディスク領域は約20%余分に必要になるが、検索精度と検索効率の点から3個に分けた。

INSPECデータベースの文献レコードは、標題、著者、著者所属機関、雑誌名、雑誌の巻・号、発行年月日、出版社、抄録、自由索引句などの31項目から構成される。このうち標題、抄録、自由索引句はQOCを用いて圧縮した。QOC辞書には、生起頻度の高い8191単語を登録するが、これを分野別に作成し圧縮率の向上を図った。著者所属機関、出版社などの圧縮にもQOCを用いた。ただし、この場合のQOC辞書は、標題、抄録、自由索引句のものとは別に作成し、各分野とも共通のものを用いた。他の項目については、1字あたり4ビットあるいは5ビットの符号化を行った。

キーワード転置ファイルには、標題、抄録、自由索引句からのキーワードを登録し、属性転置ファイルには著者、雑誌名などの索引を用意した。

(1) LOGON TSS F0026
+ PASSWORD ?
123456789ABC
KDS70001I F0026 LAST ACCESS AT 21:43:17 ON 83.341
KEQ56455I F0026 LOGON IN PROGRESS AT 21:03:44 ON DECEMBER 9, 1983
JOB NO = TSU8024 CN(01)
KEQ56951I NO BROADCAST MESSAGES
READY

(2) AIR INSPEC
(3) .FIND INFORMATION RETRIEVAL
36879 = INFORMATION
5023 = RETRIEVAL
1: 3486 DOCUMENT(S) FOUND

(4) .AND INDEXING
2: 297 DOCUMENT(S) FOUND

(5) .FIND AU=SALTON?
#1: 33 = SALTON, G.
#2: 2 = SALTOR, F.
#3: 4 = SALTSBURG, H.
#4: 1 = SALTSMAN, M.R.
#5: 1 = SALTSMAN, S.
#6: 1 = SALTSMAN, T.
#7: 2 = SALTUS, G.E.
#8: 1 = SALTYKOV, A.I.
#9: 1 = SALTYSOV, I.V.
SELECT NUMBERS: 1
+E
3: 33 DOCUMENT(S) FOUND

(6) .COMBINE 2*3
4: 8 DOCUMENT(S) FOUND

(7) .DISPLAY
4: COMBINE 2*3
1/ 8
TI = A BLUEPRINT FOR AUTOMATIC INDEXING
AU = SALTON, G. (DEPT. OF COMPUTER SCI., CORNELL UNIV., ITHACA, NY, USA)
SO = SIGIR FORUM (USA), VOL.16, NO.2, 22-38, FALL 1981
AB = SUMMARIZES SOME OF THE CURRENTLY AVAILABLE INSIGHTS IN AUTOMATIC INDEXING. THE EMPHASIS IS ON ASPECTS THAT ARE EXPECTED TO BE USEFUL IN A PRACTICAL AUTOMATIC INDEXING APPLICATIONS. THE DISCUSSION IS NECESSARILY CURSORY, BUT THE REFERENCES WILL LEAD INTERESTED READERS TO A DEEPER TREATMENT OF THE INDEXING PROBLEM
+E
2/ 8
TI = EFFECTIVE AUTOMATIC INDEXING USING TERM ADDITION AND DELETION
AU = YU, C.T., SALTON, G., SIU, M.K. (UNIV. OF ALBERTA, EDMONTON, ALBERTA, CANADA)
SO = J. ASSOC. COMPUT. MACH. (USA), VOL.25, NO.2, 210-25, APRIL 1978
AB = IN INFORMATION RETRIEVAL INDEXING IS THE TASK CONSISTING OF THE ASSIGNMENT TO STORED RECORDS AND INCOMING INFORMATION REQUESTS OF CONTENT IDENTIFIERS CAPABLE OF REPRESENTING RECORD OR QUERY CONTENT. IF THE INDEXING IS PERFORMED AUTOMATICALLY AND THE RECORDS ARE WRITTEN DOCUMENTS, AN INITIAL SET OF INDEX TERMS MIGHT BE CHOSEN BY TAKING WORDS EXTRACTED FROM DOCUMENT TITLES OR ABSTRACTS; THIS INITIAL TERM ASSIGNMENT MIGHT THEN BE IMPROVED BY ADDING RELATED TERMS CHOSEN FROM A THESAURUS, BY DELETING EXTRANEOUS OR MARGINAL TERMS, AND BY REPLACING SINGLE TERMS BY TERM COMBINATIONS AND PHRASES. FORMAL PROOFS ARE GIVEN OF THE RETRIEVAL EFFECTIVENESS UNDER WELL-DEFINED CONDITIONS OF INDEXING POLICIES BASED ON THE USE OF SINGLE TERMS, TERM ADDITIONS AND DELETIONS, AND TERM COMBINATIONS OR PHRASES

(8) +N
.END
READY

(9) LOGOFFC
RETURN CODE : 0000
CPU TIME(1.85SEC.) USE TIME(5MIN.) REGION SIZE(1056KB)
INPUT(12LINES) OUTPUT(54LINES) EXCP(166TIMES)
SESSION CHARGE(TSU8024,21:03:44) 24YEN
TOTAL CHARGE SINCE 04/01/83 (EXCEPT THIS SESSION'S) 97,711YEN
KEQ56470I F0026 LOGGED OFF AT 21:07:53 ON DECEMBER 9, 1983+
KEQ54100I SESSION ENDED

図4. AIRの使用例

5. AIRによるINSPECの検索

ここでは、図4に示した検索例従ってAIRの使用法を簡単に説明する。下線部は利用者の入力である。

- (1) AIRを使用するためTSSセッションを開設する。
- (2) AIRを起動する。データベースとしてINSPECCを指定している。データベース名を省略した場合や指定したデータベースが登録されていない場合は、利用可能なデータベースの一覧が表示されるのでメニュー選択する。
- (3) INFORMATION及びRETRIEVALをキーワードとして持つ文献を検索している。システムは、INFORMATION, RETRIEVALをキーワードとして持つものがそれぞれ36879, 5023件あり、結果として3486件見つかったことを表示している。この文献集合には集合番号1が割り当てられている。
- (4) ANDコマンドにより、キーワードINDEXINGを持つ文献集合と直前の検索集合との積集合を求めている。279件見つかった。この文献集合には集合番号2が割り当てられている。直前の検索集合との集合演算を行うコマンドは、ANDのほかにOR(和), NOT(差)がある。
- (5) FINDコマンドにより著者名がSALTON?のものを検索している。SALTON付近の著者名が一覧表示され、1を選択することにより"SALTON, G."を検索している。33件見つかった。最後の"E"の入力は一覧表示を止めることを指示している。
- (6) COMBINEコマンドにより集合番号2の297件と集合番号3の33件の積集合を求めている。8件見つかった。COMBINEコマンドで用いることができる演算記号は* (積), + (和), - (差)である。
- (7) DISPLAYコマンドにより見つかった文献を表示している。AI

Rでは標準的には複数の文献は1件ずつ新しいものから順に表示される。1件分の表示が終わると"+"が出力される。続けて表示するには復改キー(RETURNキー)を押す。表示をやめる場合は任意の文字を入力する。

(8) AIRを終了している。

(9) TSSを終了している。

6. AIRの評価

6. 1 ディスク使用量

AIRでは文献データをQOCなどのデータ圧縮技法を用いて圧縮表現にして文書ファイルに格納する。文献データそのものは1/3. 6程度に圧縮されるが、文献単位に項目見出しを付けるので、全体としては1/3程度に圧縮される。また、AIRではキーワード転置ファイルに生起位置情報を持たない。このことによりキーワード転置ファイルの大きさはほぼ半分になる。

1973年から1984年現在までのINSPEC-Cの文献データからAIR, FAIRS-Iによってデータベースを構築した経験では、AIRはFAIRS-Iに比べて文書ファイルで1/3. 5, 転置ファイルで1/3. 8, 全体として1/3. 6のディスク領域で済んだ。AIR, FAIRS-Iの使用量は、それぞれ約200, 700メガバイトであった。INSPEC-Aではこの3倍、INSPEC-Bでは1.5倍のディスクが必要であるので、AIRによってもたらされるディスクの節約の効果は非常に大きい。実際、FAIRS-Iを用いていた場合には、最大のINSPEC-Aで3年分、INSPEC-Cで5年分程度しかディスク上に置くことができなかったが、AIRを用いるようになって10年分以上のINSPECデータをすべてディスク上に置いて検索サービスを行えるようになった。

6. 2 システム応答速度

A I Rでは、文献キー集合の表現を、キーワード転置ファイル、属性転置ファイル、演算結果を格納する作業用ファイル上ですべて同一の形式としている。従って、A N D演算などを必要としない“F I N D S Y S T E M”のようなコマンドに対する処理は、Q木の索引を参照するだけであるので、極めて高速である。

A I Rでは、文献集合を10キロバイト以上の大きな単位（ブロック）でディスクに格納することによって、集合演算処理中のファイルアクセス回数を減らしている。F A I R S - I ではブロックの大きさは2048バイトに固定されている。A I Rでは、集合演算方式それ自体にも多少工夫をこらし、またF A I R S - I と比べると、文献集合の表現の大きさが1／3以下であり、ブロックの大きさが4倍以上であるので、ファイルアクセス回数は1／10以下である。システム応答速度は、まだ正確な計測は行っていないが、確実に10倍以上高速である。

7. おわりに

九州大学大型計算機センターでは、I N S P E C文献検索サービスのための情報検索システムを1984年1月に、従来のF A I R S - I からA I R第1版に置き換えた〔11〕。情報圧縮により10年分以上のI N S P E Cデータベースの遡及検索が可能となり、検索の応答時間も格段に向かっていることが確認できた。A I Rには、近い将来日本語処理機能を追加し、現在F A I R S - I で行っているJ I C S Tファイルの検索サービスをA I Rで行う予定である。

文章データを“読み”，“理解する”機能については、今後研究開発を進め、A I Rを真に高度な情報検索システムにしたいと考えている。

参考文献

- [1] 計算機マニュアル FACOM OS IV FAIRS-I 解説書, 富士通(株).
- [2] Aitchison, T. M., Martin M. D. and Smith, J. R. : Developments toward a Computer Based Information Service in Physics, Electrotechnology and Control, Inform. Storage and Retrieval, 4, 2, 177-186 (1968).
- [3] Aho, A. V. and Corasick, M. J. : Efficient String Matching: An Aid to Bibliographic Search, Commun. ACM, 18, 6, 333-340 (1975).
- [4] 松尾, 二村, 吉田: 準最適テキスト圧縮符号, 九大工学集報, 5, 2, 103-106 (1982).
- [5] 松尾, 二村, 吉田: 科学技術論文抄録における単語の統計的性質, 九大工学集報, 54, 4, 411-416 (1981).
- [6] 二村, 松尾: オンライン検索のための文献データ圧縮技法, 情報処理学会データベース・システム研究会資料34-5 (1983).
- [7] 松尾, 二村, 高木, 吉田: INSPECデータベース転置ファイル生成における不要語選択法, 九大工学集報, 54, 2, 99-105 (1981).
- [8] Salton, G. and McGill M. J. : Introduction to Modern Information Retrieval, xv+448, McGraw-Hill, New York (1983).

- [9] 篠原, 二村, 松尾: 転置ファイル内のキーワード生起位置情報について, 情報処理学会第26回全国大会講演論文集(Ⅱ), 7F-3 (1983).
- [10] 松尾, 二村, 篠原: 高速単語索引, 同上, 7F-4 (1983).
- [11] 二村, 篠原, 松尾: 情報検索システムAIRによるINSPECの検索, 九州大学大型計算機センター広報, 17, 1, 1-22 (1984).