

遺伝子-蛋白質解析システム GENAS について

久原 哲¹⁾, 高木利久²⁾, 二村祥一³⁾, 神佳え⁴⁾, 林 勝哉¹⁾, 松尾文頃³⁾

1) 九州大学農学部農芸化学科, 2) 工学部情報工学科, 3) 大型計算機センター, 4) 遺伝情報実験施設

遺伝子-蛋白質解析システム GENAS は Adbis E DBMS として EMBL Nucleotide Sequence Data Library, GenBank, NBRF Protein DataBank をデータベースとして応用プログラムの実行環境をもつデータベースシステムである。検索機能だけではなく、情報処理機能をもつことにより配列解析に有効であり、同時に個人の配列に対しても同様の解析ができるることによりその応用範囲は広い。

GENAS に登録されたこの応用プログラムは挿入・抽出を含む文字列の高速検索や長大配列の 2 次構造推定などがあり有効な解析ができるようになっている。

靈長類の反復配列である L1 ファミリーの遺伝子、蛋白質の構造解析を行なった。その結果、相同意の高い領域が存在することが明らかとなり、同時にコードしている蛋白質がウイルスの RNA 依存性 DNA ポリメラーゼと相同意がわかった。

"GENAS: A database system for nucleic acid and protein sequence analysis" (in Japanese)

Satoru KUHARA¹⁾, Toshihisa TAKAGI²⁾, Syouichi FUTAMURA³⁾, Yoshiyuki SAKAKI⁴⁾, Katuya HAYASHI¹⁾, Fumihiro MATSUO³⁾

1) Department of Agricultural Chemistry, 2) Department of Computer Science and Communication Engineering, 3) Computer Center and

4) Research Laboratory for Genetic Information, Kyushu University,

46-02, Fukuoka 812, JAPAN

A database system named GENAS, (GENe and protein Analyzing System) for computer analysis of sequence was constructed using a deductive DBMS called Adbis which manages integrated database GENEDB and application programs. GENAS enables us to retrieve any sequence data from EMBL nucleotide sequence data library, GenBank and NBRF protein sequence databank, and readily to analyze them (if necessary, together with private data).

Homology search program in application uses Wilber and Lipman's fast algorithm which allows insertion and deletion between a private sequence and database sequence. Second structure of large RNA sequence can be estimated by dynamic programming algorithm.

L1 family of repetitive DNA sequences in primate were analyzed homology among sequences using GENAS. Members showed a high homology among each other and long open reading frame in L1 family sequence has significant sequence homology to several RNA-dependent polymerase of virus.

1 はじめに

遺伝子、蛋白質は生体機能をつかさどる重要な生体高分子であり、古くから研究が行なわれ多くの研究成果が発表されている。その構成要素は、遺伝子ではアデニン(A), グアニン(G), チミン(T), シトシン(C)の4種があり、蛋白質では20種のアミノ酸である。1950年代に蛋白質はポーリングによつてα-ヘリックスという2次構造のモデルが、遺伝子ではワトソン・クリックによつて遺伝子(DNA)の2重らせん構造のモデルが出来れ、構造と機能についての研究がさかんとされるきっかけを作った。特にDNAの2重らせん構造は遺伝子の複製つまり遺伝に重要な知見を与えた遺伝から分子生物学への橋渡しを行なった。蛋白質については構造解析の手法が1950年代に確立され、蛋白質のアミノ酸配列が次々に決定されていった。しかしながら当時は遺伝子の構造解析の有効な手法がなく解析はあまり進まなかった。1970年代になり、サンガー法やマキサム-ギルバート法などの遺伝子構造解析手法の確立と遺伝子工学と呼ばれる遺伝子操作技術の普及とが相まって容易にかつ短時間で遺伝子の構造が決定できるようになつた。これ以降は遺伝子の塩基配列の発表数は飛躍的に増加し、現在では蛋白質のアミノ酸配列として発表されるもののうち約90%が直接蛋白質から配列を決定したものではなく遺伝子の上に決定されたものという状況になつている。

この遺伝子、蛋白質の配列の急激な増加に際して、配列情報のデータベース化が提案された。蛋白質に関しては1950年代からジョージタウン大学の National Biomedical Research Foundation (NBRF) の故 Dayhoff や史ラガ中心となりアミノ酸配列を収集し Atlas of Protein Sequence and Structure⁽¹⁾を出版し、1971年からは Protein Data Bank (NBRF 蛋白質データバンク)となり計算機可読な形となつている。これに対し、遺伝子では1979年にデータベース化の動きが始まり、欧洲では欧洲分子生物学研究所 (EMBL)、米国では National Institute of Health (NIH) や中心となり遺伝子データベースを作り始めた。1982年には、EMBL や EMBL Nucleotide Sequence Data Library Release 1.0 を米国では Los Alamos 国立研究所と Bolt Beranek and Newman (BBN) 社が GenBank Release 1.0 を配布し始めた。

1980年代に入り、オノコジーンと呼ばれる発癌蛋白質をコードしていきる遺伝子⁽²⁾が発見され、蛋白質の機能は不明であった。しかしデータベースとの相容性の検索により、それまでに知られていた蛋白質リシン酸化酵素、増殖因子あるいはDNA結合蛋白質などに非常に類似していることが明らかとなり発癌機構の解明に一步近づくことになつた。この結果、分子生物学の分野でもデータベースが盛んに利用されるようになつてきている。


しかししながら、我が国においては検索と処理機能を持つデータベースシステムが存在していないかった。そこで著者らは九州大学大型計算機センターの FACOM M-382 OS TV/F4 上に遺伝子・蛋白質解析システム GENAS⁽³⁾を構築した。GENAS は情報検索と情報処理の2つの機能を持ち、GenBank、EMBL Nucleotide Sequence Data Library と NBRF の Protein Data Bank をデータとし、データベース管理システムとして九州大学大型計算機センターが開発したデータベース統合支援システム Adonis⁽⁴⁾を使用した関係型データベースシステムである。

2 遺伝子の構造と蛋白質の発現機構


ここで遺伝子の構造と遺伝子にコードされている蛋白質の表現機構について簡単に述べる。この表現の機構は図1に示すように転写、プロセッシング、翻訳の3過程に分けられ、それらの過程は配列と密接な関係にある。

2-1 転写過程

表現の最初はRNAポリメラーゼと呼ばれる酵素により、DNAの情報をRNAへ転写される過程である。転写が起る部位の周辺には各遺伝子間で共通性の高い2つの配列がある。1つはHogness boxあるいはTATA boxと呼ばれるもので転写開始点の上流30塩基付近にあり次のようないくつかの配列を持つている。



ここでA,T,C,Gの下に付けた数字は出現頻度を示している⁽⁵⁾。このHogness boxのさらに約50塩基上流にCAAT boxと呼ばれる



の共通配列⁽⁶⁾があり、これらの共通配列は転写効率に影響することが知られている。これに対して転写の終了点の配列については不明であり、わずかに原核生物の転写終了の配列が明らかにならないに過ぎない。

2-2 プロセッシング過程

ポリメラーゼによる転写産物であるRNAは5'末端に7×ケレグアノシン(CAP), 3'末端にはポリアが付加される。CAPが付加される位置はポリメラーゼによる転写開始に対応し、ポリアが付加される位置の10~20塩基上流にはAATAAAのポリアシグナルと呼ばれる共通配列が存在している。

真核生物では蛋白質をコードしている遺伝子はいくつかの部分に分かれて存在しているという特徴がある。蛋白質をコードしている部分をEXON(エキソン)、していない部分をINTRON(イントロン)と呼ぶ。このような構造をとっているRNAを前駆体RNAと呼び、この前駆体RNAからINTRONが切りとられEXONのみからなる成熟メッセンジャーRNA(mRNA)ができる。この過程をスプライシングと呼ぶ。このスプライシング過程は蛋白質の配列に関係するものだけに正確さが要求され、その為にはINTRONとEXONの連結部位に何らかのシグナルが存在していると考えられ図2に示すような共通構造⁽⁷⁾が見つけられた。しかししながら

スプライシングの詳細
な機構はいまだ不明な
点が多い。

2-3 翻訳過程

アロセッティングを受
けてきた mRNA は次

にリボゾームと呼ばれる装置により蛋白
質に翻訳される。その過程はまずメチオ
ニンを示す AUG の mRNA 配列にリボゾーム
が結合し、次に表 1 に示すスクレオ
チド（コドン）に従ってアミノ酸に翻訳
され、アミノ酸間のペプチド結合が形成
され蛋白質の一次構造が完成する。

3 遺伝子-蛋白質解析システム GENAS

3-1 データベース

遺伝子の塩基配列データベースとしては
は欧洲では EMBL がデータ収集配布を行
なう、そして EMBL Nucleotide Sequence
Data Library と米国では NIH により
Los Alamos 国立研究所がデータ収集を行ない BBN 社がデータ配布を行なう、
いは GenBank、および NBRF がデータ収集配布を行なう、
いは NBRF Nucleotide Data Bank の 3つがある。これらのデータベースは 1982 年から公共データベースとして
無料で磁気テープあるいはフロッピーディスクによる配布が開始されており
版権などの制限はない。GenBank、NBRF は年半回また EMBL は年 2 回更新され
ている。

蛋白質のアミノ酸配列のデータベースとしては NBRF の Dayhoff らの *Atlas of Protein Sequence and Structure* を出版しておき、1983 年からは公共データベース NBRF Protein Data Bank として無料で配布されている。これらのデータベースの増加は塩基配列に関する年間 150 万塩基以上になっている。

これら 3 つのデータベースはそれぞれ異なり書式を用いて書かれしており、その例を図 3 に示す。EMBL を例にとって構造を説明すると 1 つの遺伝子の情報は 1 つのエントリーとして格納されている。各エントリーはまず ID 行で遺伝子を表わすコード名、AC 行でアセッション番号、DT 行で入力された日付、DE 行で遺伝子の定義、KW 行でキーワード、OS 行で生物種、OC 行で分類、RN 行で文献番号、RT 行で文献題目、RA 行で著者名、RL 行で文献名、CC 行で注釈、FH 行で feature Table の見出し、FT 行で feature Table、SQ 行で配列の見出し、その次に配列、最後に // 行で終了する順になつてある。特に分子生物学の研究者が必要とする情報は FT 行に示されており feature table があり、各情報の位置とコードが key, From, To, Description の順で示されている。

著者らのシステムでは、これらのデータベースの中の塩基配列として EMBL、
GenBank および蛋白質のアミノ酸配列として NBRF Protein Data Bank を基に
して新規に関係型データベース GENEDB を構築している。GENAS を構築する上




図 2 スプライシング部位の共通配列

表 1 遺伝コード表

First position (5'-end)	Second position				Third position (3'-end)
	U	C	A	G	
U	Phe	Ser	Tyr	Cys	U
	Phe	Ser	Tyr	Cys	C
	Leu	Ser	Stop	Stop	A
	Leu	Ser	Stop	Trp	G
C	Leu	Pro	His	Arg	U
	Leu	Pro	His	Arg	C
	Leu	Pro	Gln	Arg	A
	Leu	Pro	Gln	Arg	G
A	Ile	Thr	Asn	Ser	U
	Ile	Thr	Asn	Ser	C
	Ile	Thr	Lys	Arg	A
	Met	Thr	Lys	Arg	G
G	Val	Ala	Asp	Gly	U
	Val	Ala	Asp	Gly	C
	Val	Ala	Glu	Gly	A
	Val	Ala	Glu	Gly	G


```

DATABASE(GENEDB)
  L('EMBL + GENBANK + PROTEIN DATABASE')
*
DEF(REF < RF#ID)
  L('REFERENCE CODE')
*
DEF(RNA < RF)
  L('RNA OR cDNA')
*
DEF(FR < RF)
  L('FRAGMENT')
*
DEF(DE : RF -> DEF)
  L('DEFINITION')
*
DEF(OS < RF#GEN#SPEC)
  L('ORGANISM')
*
DEF(OC < RF#LVL#TAX)
  L('ORGANISM CLASSIFICATION')
*
DEF(HS < RF#GEN#SPEC)
  L('THE MOST COMMON HOST SPECIES')
*
DEF(HC < RF#LVL#TAX)
  L('HOST CLASSIFICATION')
*
DEF(BIB : RF#SN -> BI)
  L('BIBLIOGRAPHIC INFORMATION')
*
DEF(KY < RF#KEY)
  L('KEYWORD')
*
DEF(AUTH < RF#AU)
  L('AUTHOR')
*
DEF(DC < RF#DS)
  L('DATA COMPILE')
*
DEF(YEAR < RF#YR)
  L('YEAR')
*
DEF(FN : RF -> NFTE)
  L('NUMBER OF FEATURE TABLE ENTRIES')
*
DEF(FT : RF#FTEN -> KEY#FROM#TO#DESCR)
  L('FEATURE TABLE')
  I(KEY, FROM, TO)
  *
DEF(SH : RF -> ABC#T#G#U#Y#R#AB)
  L('SEQUENCE HEADER')
*
DEF(LN : RF -> LEN)
  L('LENGTH OF SEQUENCE')
*
DEF(SQ : RF#SN -> SEQ)
  L('SEQUENCE')
*
DEF(RF)      KEY
  T(14)    L('REFERENCE CODE')
*
*** PROTEIN IF RF > 1,000,000,000; OTHERWISE NUCLEOTIDE.
*
DEF(ID)      T(C18)  L('SHORT IDENTIFICATION')
*
DEF(GEN)     T(C100) L('GENUS')
DEF(SPEC)    T(C50)  L('SPECIES')
*
DEF(LVL)     T(I2)   L('LEVEL IN TAXONOMIC TREE')
DEF(TAX)     T(C50)  L('ENTRY IN TAXONOMIC CLASSIFICATION')
*
DEF(DEF)     T(C600) L('DEFINITION WRITTEN IN ENGLISH')
DEF(BI)      T(C2000) L('BIBLIOGRAPHIC INFORMATION')
DEF(KEY)    T(C50)  L('KEY WORD')
DEF(AU)      T(C50)  L('AUTHOR')
DEF(DS)      T(C8)   L('DATA SOURCE')
DEF(YR)      T(I2)   L('YEAR')
*
DEF(NFTE)    T(I2)   L('NUMBER OF FEATURE TABLE ENTRIES')
DEF(FTEN)    T(I2)   L('FEATURE TABLE ENTRY NUMBER')
DEF(KEY)    T(C10)  L('FEATURE TABLE KEY NAME')
DEF(FROM)   T(I4)   L('ENDPOINT SPECIFICATION')
DEF(TO)     T(I4)   L('ENDPOINT SPECIFICATION')
DEF(DSCR)   T(C250) L('MORE INFORMATION ABOUT FEATURE')
*
DEF(A)       T(I4)   L('NUMBER OF ADENINE BASES')
DEF(C)       T(I4)   L('NUMBER OF CYTOSINE BASES')
DEF(T)       T(I4)   L('NUMBER OF THYMINE BASES')
DEF(G)       T(I4)   L('NUMBER OF GUANINES')
DEF(U)       T(I4)   L('NUMBER OF URACIL BASES')
DEF(Y)       T(I4)   L('NUMBER OF PYRIMIDINE BASES')
DEF(R)       T(I4)   L('NUMBER OF PURINE BASES')
DEF(AB)      T(I4)   L('NUMBER OF ANY BASES')
*
DEF(LEN)     T(I4)   L('LENGTH OF SEQUENCE')
*
DEF(SN)      T(I4)   L('SEQ NUMBER')
DEF(SEQ)     T(C500) L('NUCLEOTIDE/PROTEIN SEQUENCE')

```

図4 データ定義

た。最も重要な FT (feature Table) については NFTE (feature Table の エントリ一数) を作り RF X FTEN の直積をドメインとして KEY X FROM X TO X DESCRIPTOR の直積をコードメイクとする関係としている。最後に 3 つのデータを区別するため DC (データ構造パッケージ) の関係を作った。これらの中でも転置ファイルを作るものは FT のみとした。この定義に従って 3 つのデータより関係型データベース GENEDB を作った。

3-2 データベースシステム

前述の GENEDB をデータベースとして GENAS を作る上で次の 2 点に重点を置いていた。

- ① 情報の検索機能を持つ。ただし検索手法は簡単であることが望ましい。
- ② 情報の処理機能を持つ。特にデータが一次構造 (配列) であり、共通配列とはいうものの変異があり配列の情報を得るには単純な文字列の検索だけでは不十分であり種々の処理を行なう必要がある。この 2 点を検討し GENAS のモードを図 5 に示すように作った。

3-2-1 情報検索

まず情報の検索機能については、分子生物学の分野の研究者は計算機を使つた経験があまりないのが、Adbis の推論機能を直接用いる検索より、Adbis の情報検索型コマンドを使用することを考へた。次に検索を考えると、その検索のほと

などがキーワードによる検索であり、その他の検索、例えば詳細な分類による検索などはほとんど行なわれないと考えられるので GENAS では情報検索型コマンドで検索可能な領域は KW(キーワード)、AU(著者名)、ID(コード名)とし、キーワードに重点をおくことにした。基となるデータのキーワードでは不足なので前述の DE 行、KW 行、RT 行、OS 行から単語を切り出しすべてキーワードとした。

3-2-2 情報処理機能

遺伝子あるいは蛋白質解析のデータベースシステムでは一般の学術情報データベースとは異なり、前述したように構造と機能の関係が一意的に決定されておらず不确定な要素が多いため、定形の処理だけではなく各種の処理がモジュール環境を持たなければならぬ。

応用プログラムとのインターフェース： MOP と呼ばれるコマンドプロシジャーを経由して応用プログラムを起動している。ただし応用プログラムの多様性および各応用プログラムのデータ要求の多様性から MOP の中で応用プログラムの選択を行ない、必要なデータあるいは環境の設定を行なっている。

応用プログラム： 現在 GENAS に登録されている応用プログラムの一覧を表すに示した。応用プログラムの実行環境では特に個人が所有している配列に対してもデータベース中の配列と同様な処理ができるようにした。処理のダイアグラムを図 5 に示した。

分子生物学の分野では、先に紹介したようにオニコジーンの発見以来、実験を得た配列についてにはデータベースの配列と相同性を検索することが一般的になつてきている。この相同性の検索では文字列の完全一致ではなく文字列の不一致あるいは挿入欠失を含む一致を探さなければならぬ。不完全一致の相同性のプログラムについては Wilber, Lipman らが開発したアルゴリズム⁽⁸⁾がよく用いられている。遺伝子の 2 次構造の推定にはダイナミックプログラミングの手法が用




図 5 GENAS のモード遷移図

Adbis のコマンド呼び出し機能を使用

表 2 GENAS の応用プログラム

統計処理
塩基の出現頻度 コドンの出現頻度 類似性の統計処理
一次構造の文字列解析
相同性の検索 遺伝子からアミノ酸への翻訳 アミノ酸から遺伝子への逆翻訳 任意の文字列の検索
二次構造の予測
蛋白質の二次構造の予測 遺伝子の二次構造の予測

いられ計算時間の短縮を行なつているものがある⁽⁹⁾。

3-3 実際例（壺長類に存在する反復配列 L1 ファミリーの一構造の比較）⁽¹⁰⁾

著者らのグループは高等動物の遺伝子の特徴の一つである反復配列の一つである L1 ファミリーの 6 個 (L1Nc1 ~ L1Nc6) の塩基配列を決定し GENAS にトローリー構造の解析を行なつた。その結果図 7 に示すように L1 ファミリーの間には 90% 以上の相同意があり、その中の L1Nc4 に




図 7 L1 ファミリーの構造と共通配列




図 6 検索のダイアグラム



図 8 L1 のアミノ酸配列とウイルスの RNA 依存性 DNA ポリメラーゼの相同意

は 92 アミノ酸残基から成る蛋白質がコードされている領域があることが明らかとなつた。特に蛋白質をコードしている領域については他の種の L1 ファミリーと 65% 以上の相同意があった。蛋白質をコードしている領域の相同意からみて L1 ファミリーは進化的に保存されている蛋白質から誘導されてきたものであると考えられる。

次に、この保存された蛋白質について検討した結果、図 8 に示すように、ウイルスの RNA 依存性 DNA ポリメラーゼと部分的に強い相同意があることが明らかとなつた。もし、コードしている蛋白質に逆転写活性があれば L1 ファミリーの分散の原因を考える上で重要な知見となるものである。

参考文献

- 1) Dayhoff,M.O., et al.(ed.) :Atlas of protein sequence and structure, Vol.1, National Biomedical Research Foundation, Silver Spring, Md.(1965)
- 2) Czernilofsky,A., et al. : Corrections to the nucleotide sequence of src gene of Rous sarcoma virus, Nature, Vol.301, pp. 736-738 (1981)
- 3) Kuhara,S., et al. :GENAS: A database System for Nucleic Acid Sequence Analysis, Nucleic Acids Res., Vol.12, pp.89-99 (1984)
- 4) 松尾文穂,二村祥一,高木利久 :推論関係型データベース管理システムAdbis, 情報処理学論文誌, Vol.124, pp.249-255 (1983)
- 5) Lewin,B. :"GENES", Jhon Wiley & Sons, New York (1983)
- 6) Proudfoot,N.J., et al. :Structure of the Genes that do not Rearrange, Science, Vol.209, pp.1329-1336 (1980)
- 7) Lewin,B. :Alternatives for splicing: Recognizing the End of Introns, Cell, Vol.22, pp.324-326 (1980)
- 8) Wilber,W.J. and Lipman,O.J. :Rapid Similarity Searches of Nucleic acid and Protein Data Bank, Proc. Natl. Acad. Sci. U.S.A., Vol.80, pp.726-730 (1983)
- 9) Zuker,M. and Stiegler,P. :Optimal Computer Folding of Large RNA Sequence using Thermodynamics and Auxiliary Information, Nucleic Acids Res., Vol.9, pp.133-148 (1981)
- 10) Hattori,M. et al. :L1 family of repetitive DNA sequences in primates may be derived from a sequence encoding a reverse transcriptase related protein, Nature, Vol.321, pp.625-628 (1986)