

生物配列解析基礎

配列データベースとホモロジー検索

法政大学 生命科学部
応用植物科学科

大島 研郎



大島 研郎(おおしま けんろう)教授

- 専門(担当)分野** 植物細菌学、植物メディカルゲノム学
- 経歴** 東京大学アグリバイオインフォーマティクス人材養成ユニット 特任助教、東京大学大学院農学生命科学研究科特任准教授
- 主な業績** 植物病原細菌ファイトプラズマの全ゲノム解読、ファイトプラズマの病原性因子の解析など

本日の講義資料

ホーム > 教育プログラム > 各講義のページ > 1. 生物配列解析基礎

1. 生物配列解析基礎

授業の目標・概要

生命科学のためのデータベースの利用と基本的な解析手法について講義します。配列データベースや機能データベースの使用法を紹介するとともに、ホモロジー検索、モチーフ解析、Perlプログラミング、系統解析などの基本的な手法について、実習形式で解説します。バイオインフォーマティクス関連の各種データベースにアクセスしたことがない人は、ぜひ本講義を受講して下さい。

担当教員

清水謙太郎 (東大・農・応用生命工学専攻 / 教授)
大島研郎 (法政大学生命科学部 / 教授)

お知らせ

ご自身のノートPCを利用される場合はこちらを参考にして必要なソフトウェアを予めインストールしておいてください。

講義日程 (平成29年度)

1. 平成29年04月19日 (PC使用)

講師：大島研郎

- kiso1
- Mgenitalium.faa
- Mpneumoniae.faa
- parse-blast7.pl
- test1.seq
- test2.seq
- test3.seq
- Ureaplasma.faa


本日の講義で使用する、Webページへのリンクが載せてあります。

塩基配列の決定 : DNAシーケンス

DNA塩基配列決定のための高速で効率のよい方法が最初に編み出されたのは、1970年代半ばのことである。2つの別々の方法がほぼ同時に公表された。


- ジデオキシ法 (dideoxy chain termination method; Sanger et al., 1977)**。チェーンターミネーター法ともいい、一本鎖DNA分子の配列を決定する方法である。酵素を使って相補的な配列のポリヌクレオチド鎖を合成するが、このとき特定のヌクレオチドの位置で反応が停止するようにしておく。
 - 化学分解法 (chemical degradation method; Maxam and Gilbert, 1977)**。二本鎖DNA分子の配列を決定する方法である。特定のヌクレオチドの位置で分子を切断する化学的な処理を行う。
- 両方法とも最初と同じように広く行われていたが、近年ではジデオキシ法がとくにゲノムの塩基配列決定で多用されている。

デオキシヌクレオチド




DNAポリメラーゼによって、伸長反応が進む

ジデオキシヌクレオチド



伸長反応が進まない



9



ABI3100シーケンサー

◆当初は平板ゲルで電気泳動していたが、後にキャピラリー電気泳動による機器が普及するようになった




図 10-13

自動 DNA シークエンサーからの読取りデータを示す配列出力ファイル。Phred にコールされた配列が、図の上段に左から右に示してある。電気泳動を行った部分に対する 4 色のシグナルの分布が、ヒストグラムで示されている。出力は X 軸に異なる色でそれぞれの塩基を示し、シグナルの強度を Y 軸に示している。DNA 断片には、非常にはっきりとしたシャープなピークを示すものや、横に広がって隣のシグナルと重なり合ってしまうものもある。この例では、出力ファイルの右端の部分では、ピークの高さが低く、他と重なり合っていることからわかるように、配列の品質が非常に悪い。515 の位置では(X で印した)、二つのピークが重なっているために、Phred はその塩基をコールすることができなかった。

10

核酸配列データベース

- GenBank, DDBJ, EMBLのデータベースは、3者が情報交換しながら連携して、“国際データベース”として運営・維持されている

GenBank (National Center for Biotechnology Information)
<http://www.ncbi.nlm.nih.gov/>

DDBJ (日本DNAデータバンク)
<http://www.ddbj.nig.ac.jp/>

EMBL (European Bioinformatics Institute)
<http://www.ebi.ac.uk/embl/index.html>

アミノ酸配列データベース

UniProt (Universal Protein Resource)
<http://www.uniprot.org/>


- データベースとは、関連性のある一定の情報を集めて、一定のフォーマット (様式) に従って使いやすいように整理したもの。大量の情報を高速に処理することができる。

11

DDBJ

日本DNAデータバンク。GenBankやEMBLと連携して国際塩基配列データベースを構築している。
<http://www.ddbj.nig.ac.jp>

12



データベース検索のページへ

ホモロジー検索のページへ

アライメント、系統樹作成



getentry --アクセッション番号等によるエントリ検索-- [Engli]

ID :

DNA データベース : DDBJ / GenBank / EMBL WGS

Protein データベース : UniProt PDB DAD Patent

取得方法 :

出力形式 : フラットファイル(DDBJ)

出力形式 : default

上限 : 10 件

AP009356
と入力

LOCUS	AP009356	80504 bp	DNA	linear	BCT 15-DEC-2007
DEFINITION	Onion yellows phytoplasma OY-W genomic DNA, partial sequence.				
ACCESSION	AP009356				
VERSION	AP009356.1				
KEYWORDS	-				
SOURCE	Onion yellows phytoplasma OY-W				
ORGANISM	Onion yellows phytoplasma OY-W				
	Bacteria; Tenericutes; Mollicutes; Acholoplasmatales; Acholoplasmataceae; Candidatus Phytoplasma; Candidatus Phytoplasma asteris.				
REFERENCE	1 (bases 1 to 80504)				
AUTHORS	Oshima,K., Kakizawa,S., Arashida,R., Kagiwada,S. and Namba,S.				
TITLE	Direct Submission				
JOURNAL	Submitted (02-MAR-2007) to the DDBJ/EMBL/GenBank databases. Contact:Shigetou Namba The University of Tokyo Graduate School of Agricultural and Life				

13

National Center for Biotechnology Information

<http://www.ncbi.nlm.nih.gov/>

NCBI Resources How To My NCBI Sign In

All Databases

NCBI Home
Resource List (A-Z)
All Resources
Chemicals & Bioassays
Data & Software
DNA & RNA
Domains & Structures
Genes & Expression
Genetics & Medicine
Genomes & Maps
Homology
Literature
Proteins
Sequence Analysis
Taxonomy
Training & Tutorials
Variation

Welcome to NCBI
The National Center for Biotechnology Information advances science and health by providing access to biomedical and genomic information.
[About the NCBI](#) | [Mission](#) | [Organization](#) | [Research](#) | [RSS Feeds](#)

Get Started
[Tools](#): Analyze data using NCBI software
[Downloads](#): Get NCBI data or software
[How-To's](#): Learn how to accomplish specific tasks at NCBI
[Submissions](#): Submit data to GenBank or other NCBI databases

Popular Resources
PubMed
Bookshelf
PubMed Central
PubMed Health
BLAST
Nucleotide
Genome
SNP
Gene
Protein
PubChem

14

All Databases

15

データベースの統合検索システム

主なデータベースは、PubMed・ヌクレオチドシーケンスデータベース・タンパク質シーケンスデータベース・ゲノムシーケンスデータベース・3D高分子構造データベース等。それぞれのデータベースは、関連付けがされており一度に多くのことが調べられる。

例えば「phosphofructokinase」と入力してみる

NCBI Resources How To Sign in to NCBI

All Databases

NCBI Home
Resource List (A-Z)
All Resources
Chemicals & Bioassays
Data & Software
DNA & RNA
Domains & Structures
Genes & Expression
Genetics & Medicine
Genomes & Maps
Homology
Literature

Welcome to NCBI
The National Center for Biotechnology Information advances science and health by providing access to biomedical and genomic information.
[About the NCBI](#) | [Mission](#) | [Organization](#) | [NCBI News](#) | [Blog](#)

Submit
Deposit data or manuscripts into NCBI databases

Download
Transfer NCBI data to your computer

Learn
Find help documents, attend a class or watch a tutorial

Popular Resources
PubMed
Bookshelf
PubMed Central
PubMed Health
BLAST
Nucleotide
Genome
SNP
Gene
Protein
PubChem

16


NCBI Entrez, The Life Sciences Search Engine

Search across databases [Help](#)

Result counts displayed in gray indicate one or more terms not found

5977	PubMed: biomedical literature citations and abstracts	74	Books: online books
3453	PubMed Central: free, full text journal articles	262	Images: images from full text resources at NCBI
none	Site Search: NCBI web and FTP sites	13	OMIM: online Mendelian Inheritance in Man
6639	Nucleotide: Core subset of nucleotide sequence records	none	dbGaP: genotype and phenotype
878	EST: Expressed Sequence Tag records	295	UniGene: gene-oriented clusters of transcript sequences
26	GS: Genome Survey Sequence records	33	CDD: conserved protein domain database
14760	Proteins: sequence database	72	UniSTS: markers and mapping data
561	Genomes: whole genome sequences	15	PopSet: population study data sets
162	Structure: three-dimensional macromolecular structures	10684	GEO Profiles: expression and molecular abundance profiles
none	Taxonomy: organisms in GenBank	3	GEO DataSets: experimental sets of GEO data
1	SNP: single nucleotide polymorphism	none	Epigenomic: Epigenetic maps and data sets
none	dbVar: Genomic structural variation	none	Cancer Chromosomes: cytogenetic databases
2925	Gene: gene-centered information	29	PubChem BioAssay: bioactivity screens of chemical substances
none	SRA: Sequence Read Archive	1	PubChem Compound: unique small molecule chemical structures
7639	BioSystems: Pathways and systems of interacting molecules	68	PubChem Substance: deposited chemical substance records
11	HomoloGene: eukaryotic homology groups	200	Protein Clusters: a collection of related protein sequences
14	GENSAT: gene expression atlas of mouse central nervous system	1	OMIA: online Mendelian Inheritance in Animals
566	Probe: sequence-specific reagents	none	BioSamples: biological material descriptions

ホモロジー検索(相同性検索)とは？



アラインメント

MIGMMIT } 二つのアミノ酸配列を整列化させるには
MMIGPIT } どのように並べればよいか？

アラインメント(並置)

- 2つの配列を要素ごとに対応づけて並べる操作
- 進化の過程で生じ得る配列要素の挿入・欠失を ギャップ(-) に対応づける

グローバルアラインメント

- 配列全体の類似性を考慮

a = M-IGMMIT

b = MMIGP-IT

ローカルアラインメント

- 局所的な類似性を考慮

a = MIGMMIT---

b = ---MMIGPIT

アラインメントスコアの計算

- 配列の類似度 = アラインメントのスコア
- アラインメントのスコアの計算
 - 対応する各要素の類似度スコアの和
 - スペースの挿入にはペナルティを適用

AFDC $s(A, A) + s(F, E) + s(D, E) + s(C, C) = 8$

AEEC $3 \quad -7 \quad 3 \quad 9$

AFDGC $s(A, A) + s(F, E) + s(D, E) + \text{space} + s(C, C) = 0$

AEE-C $3 \quad -7 \quad 3 \quad -8 \quad 9$

完全に一致するアミノ酸や、類似アミノ酸には高い点数を与えたい
→ 各アミノ酸の点数はどのように求めればよいか？

BLOSUMスコア (Henikoffらの方法)

BLOSUM: BLocks amino acid Substitution Matrix

- 同一ファミリータンパク質のギャップなしでアラインメントされた領域(ブロック)に対し、アミノ酸の置換の頻度を調べて作成

- 良く似た配列の寄与が優勢になりすぎないように、例えば62%一致のパターンをまとめてBLOSUM62を作るのに用いる。

BLOSUM50マトリックス

	A	R	N	D	C	E	G	H	I	L	K	M	F	P	S	T	W	Y	V
A	5	-2	-1	-2	-1	-1	0	-2	-1	-2	-1	-3	-1	1	0	-3	-2	0	
R	-2	7	-1	-2	-4	1	0	-3	0	-4	-3	3	-2	-3	-3	-1	-3	-1	
N	-1	-1	7	2	-2	0	0	0	1	-3	-4	0	-2	-4	-2	1	0	-4	
D	-2	-2	2	8	-4	0	2	-1	-1	-4	-4	-1	-4	-5	-1	0	-1	-5	
C	-1	-4	-2	-4	13	-3	-3	-3	-2	-2	-3	-2	-2	-2	-4	-1	-1	-5	
E	-1	0	0	-3	7	2	-2	1	-3	-2	2	0	-4	-1	0	-1	-1	-3	
G	-2	-2	0	2	-3	2	6	-3	0	-4	-3	1	-2	-3	-1	-1	-3	-2	
H	-1	-3	0	-1	-3	2	-3	8	-2	-4	-2	-3	-4	-2	0	-2	-3	-4	
I	-2	0	1	-1	-3	1	0	-2	10	-4	-3	0	-1	-1	-2	-1	-2	-3	
L	-1	-4	-3	-4	-2	-3	-4	-4	-4	5	2	-3	-2	0	-3	-3	-1	-3	
K	-1	3	0	-1	-3	2	1	-2	0	-3	6	-2	-4	-1	0	-1	-3	-2	
M	-1	-2	-2	-4	-2	0	-2	-3	-1	2	3	-2	7	0	-3	-2	-1	0	
F	-3	-3	-4	-5	-2	-4	-3	-4	-1	0	1	-4	0	8	-4	-3	-2	1	
P	-1	-3	-2	-1	-4	-1	-2	-2	-3	-4	-1	-3	-4	-1	10	-1	-4	-3	
S	1	-1	0	-1	0	-1	0	-1	-3	-3	0	-2	-3	-1	5	2	-4	-2	
T	0	-1	0	-1	-1	-1	-2	-2	-1	-1	-1	-1	-1	-2	2	6	-3	-2	
W	-3	-3	-4	-5	-5	-1	-3	-3	-3	-3	-3	-1	-1	-4	-4	15	2	-3	
Y	-2	-1	-2	-3	-3	-1	-2	-3	-2	-1	-2	0	-4	-3	-2	-2	8	-1	
V	0	-3	-3	-4	-1	-3	-4	-4	-4	1	1	-3	-1	-1	-3	-2	0	-3	



Needleman-Wunschのアルゴリズム

- 2つの配列の最適なグローバルアラインメントを、ダイナミックプログラミング(動的計画法)により求める。

Smith-Watermanのアルゴリズム

- 2つの配列の部分配列間の一致を探索する
- 最も高いスコアをもつ一致箇所を示すアラインメントを求める
→ ダイナミックプログラミング(動的計画法)

25


FASTAとBLAST

- ダイナミックプログラミングによる方法は、 mn に比例した時間を要する (m, n は配列の長さ)
- 配列データベースに登録されている配列の数は膨大
- 効率的な手法の利用
- FASTA
 - 一致する配列の断片を高速に検索、限られた候補に対して正確な手法を適用
 - Lipman and Pearson (1985)
- BLAST
 - 局所的に類似の部分配列を高速に検索
 - Altschul (1990)

26

BLAST検索


- 配列を固定長の断片(ワード)に区切り、ワード単位で類似する断片を検索する。
- これらを類似度が最大になるまで両方向に伸ばして局所的なアラインメントを行い、最後にこれらを結合して、最終的なアラインメントを行う手法。
- 他の方法に比べて高速であり、ホモロジー検索の方法として最もよく利用されている。



27

<http://www.ncbi.nlm.nih.gov/>

28



プログラム	質問配列 (query)	検索対象
protein blast	アミノ酸配列	アミノ酸配列データベース
blastx	塩基配列	アミノ酸配列データベース
nucleotide blast	塩基配列	塩基配列データベース
tblastn	アミノ酸配列	塩基配列データベース
tblastx	塩基配列	塩基配列データベース

BLASTP検索 (protein blast)

http://blast.ncbi.nlm.nih.gov/Blast.cgi

```
>sample1
MNRVFLFGKLSFTPNRLQTKNGTLGATFSMECLDS
SGFNNAKSFIRVTAWGKVASFIVAQNPVGLFVEG
RLTTYKITNSENKNTYALQVTADKIFHPDEKTTNE
EPIKSTVVDSPFMNPKASVTEAEFEQAFPHQDET
FNNITPIFENDVQLEESDD
```

①配列をコピーする
(">"の行は入れても入れなくてもよい)

③データベースを選ぶ
(nr)

④「BLAST」を押す

nr : 冗長性をなくした(non-redundant)アミノ酸データベース

29

NCBIのref_seq番号
Geneデータベース

```
>|ref|NP_109917.1|G| single-stranded DNA binding protein [Mycoplasma pneumoniae M129]
sp|F75542.1|SSB_MYCPN RecName: Full=Single-stranded DNA-binding protein; Short=SSB;
AltName: Full=Helix-destabilizing protein
|gb|AB96250.1|G| single-stranded DNA binding protein [Mycoplasma pneumoniae M129]
Length=166

GENE ID: 877060 ssb | single-stranded DNA binding protein
[Mycoplasma pneumoniae M129] (10 or fewer PubMed links)
スコア E-value
Score = 202 bits (514), Expect = 7e-51, Method: Compositional matrix adjust.
Identities = 96/165 (58%), Positives = 126/165 (76%), Gaps = 5/165 (3%)
相同性(identity) 相同性(similarity)ギャップ
Query 1 MNRVFLFGKLSFTPNRLQTKNGTLGATFSMECLDSSGFNNAKSFIRVTAWGKVASFIVAQ 60
MNRVFLFGKLSF PN+LQT+ +GA+FS+ C+DSSGFN++KS+IR+TAWGKVASF++
Sbjct 1 MNRVFLFGKLSFDPNKLQTRTNNIGASPSLACIDSSGFNDSKSYIRITAWGKVASFVLT 60

Query 61 NPGVLMFVEGRLTTYKITNSEN---KNTYALQVTADKIFHPDEKTTNEEPI-KSTVVD 115
FG +FVEGRL+TYK+ N + K TYALQV ADK++ PDE+ + E+P+ K+TV+DS
Sbjct 61 KPGDSV FVEGRLSTYKMNRSDDFNSKATYALQVIADRVYRPFDEENSLQPVDRKATVIDS 120

Query 116 PFMNPKASVTEAEFEQAFPHQDETDFNNITPIFENDVQLEESDD 160
PF+ K+ TE E QAFF + + ++I PI ND QLEESDD
Sbjct 121 PFLAAKTNATENELAQAFPI SLDDDEDDINPI LNDSQLEESDD 165
```

↑
アラインメント

Query : 質問配列
Sbjct : Blast検索の結果, ヒットした配列

↑
全長ではないので注意
(本当は, ...SDDEまで続く)

30

E-value

- E valueは, 現在のデータベースにおいて, 全く偶然に同じスコアになる配列の数の期待値であり, E valueが小さいほど偶然には起こり得ないことを示している.
- BLAST検索の際にE valueのしきい値を設定することで, その値よりも小さいE valueの検索結果しか出力されなくなる.

31

検索結果の表示件数
E-valueのしきい値
BLAST検索時のWordサイズ
マトリックスの種類を選ぶ
ギャップのスコア設定
E-value計算時の設定
冗長配列を取り除く場合はチェック
冗長配列を取り除く場合の設定
小文字を無視する場合の設定

30

blastx

塩基配列を入力



6通りのreading frameのすべてについて翻訳し、アミノ酸配列データベースに対して検索してくれる


```
S S * E V K E E K D I H H K L V K K Q
F K V R S E R G * * Y S A K S G K K S
H V K S * K R K R I L I I S * F R K K I
TACTTGAAATGAGATGAAAGAGAAGGAATAGTTACTACGAAATCTGGAAAAAACTA
      10      20      30      40      50      60
ATGAAC TTTACTCTACTTTCTCTTCTTATCAATATGATGCTTTAGAAC TTTT TTTGAT
M N F T L L S L P Y Q Y D A L E P F F D
* T L L Y F L F L I N M M L * N L F L I
E L Y S T F S S L S I * C F R T F F * Y
```

- ・塩基配列を決定したが、何がコードされているかわからないとき
- ・non-coding領域に、タンパク質がコードされていないかどうか、調べたいときなど

```
>sample2
ATGAAATTAAGAATCTGCGAACTTGTATTAAATAAACTTTAATTACTAAAATAAAATAGAACTATTTTAGAACTAAAA
AAAAGCCATCAAAATATGCCTATATTTGCATGATAAAGATATTTATCAAAATGATAAAGAGGCTCAATTGAATGGTAAAA
AAGTAGGAGATATAAAGCTCCTCATGGCATATATTTAAGATTTAATTTACATGATACAAAAAATATCGCTCAATGG
TTTAATACTGAGGATAATTTGTTTCCAAAATAAAAGGTAGATTTAGTGATGCCTTAATGTATATGATTCATGCTAATAGGTC
```



blastx検索



blastn (nucleotide blast)

```
>sample3
TTGAAGAGGACTTGGAACTTCGAT
```

①配列をコピーする
(">"の行は入れても入れなくてもよい)

③データベースを選ぶ
(nr/nt)

④「BLAST」を押す



① Your search parameters were adjusted to search for a short input sequence.

と表示され、短い配列用の設定で検索される

tblastn

アミノ酸配列を入力



データベース上の塩基配列を、6通りのreading frameのすべてについて翻訳し、このアミノ酸配列データに対して検索してくれる

- ・EST配列やドラフトゲノムなど、アノテーション情報が整備されていないデータから相同な配列を探したいときに便利

tblastx

塩基配列を入力



6通りのreading frameのすべてについて翻訳



データベース上の塩基配列も、6通りのreading frameのすべてについて翻訳し、このアミノ酸配列データに対して検索

- ・質問配列、データベースとも、アノテーション情報が整備されていない場合に有効

BLAST検索 (GenomeNet)



```
>sample5
MDENETQFNKLNQVKNKLIKGVFVGGAGNIVDASLYHYFN
LASENIHFYAINSDLQHLAFKTNVKNKLLIQDHTNKGFGAGG
DPAKGASLAISFQEQFNTLTDGYDFCILLVAGFGKGTGTGATP
VFSKILKTKKILNVAIVTYPVSLNEGLTVRNKATKGLLELNKA
TDSYMLFCNEKCTNGIYQLANTEIVSAIKNLELITLPLQQN
IDFEDVRAFFQTKKTNQDQLFTVTHPPFSPFSDSKDSIEQFA
KQFKNFEKVSYPDHSIVGAKVLLKANINQKIVKLNFKIQD
I IWTKLDNYQLEIRLGVDFVTTIPNIQIFILSEHKNPVSLPI
DNKSTENNQNKLLLDLDELKELGMKYVVKHQNQIY
```

- ①配列をコピーする (">"の行は入れても入れなくてもよい)
- ②貼り付ける
- ③Favorite organisms を選択
- ④「mge mpn uur」と入力
mge: *Mycoplasma genitalium*
mpn: *Mycoplasma pneumoniae*
uur: *Ureaplasma parvum*
- ⑤「Compute」を押す

Entry	bits	E-val
Top 10 <input type="button" value="Clear"/> <input type="button" value="Select operation"/> <input type="button" value="Exec"/>		
<input checked="" type="checkbox"/> mge:MG_224ftsZ: cell division protein FtsZ ; K03531 cell divisi...	679	0.0
<input checked="" type="checkbox"/> mpn:MPN317ftsZ, F10_orf380: cell division protein FtsZ ; K03531...	358	e-100
<input checked="" type="checkbox"/> uur:UU317 hypothetical protein	28	0.53
<input checked="" type="checkbox"/> mpn:MPN257galE, A65_orf338: UDP-glucose 4-epimerase	28	0.68

Ureaplasmaは、ftsZを持っていないことがわかる

- 大量のQuery配列についてBLAST検索を行いたい
- 自分の持っている未公開のデータに対して検索したい
- ホモロジー検索を用いて比較ゲノム解析を行いたい



Stand-alone BLASTを利用する
(ローカルなコンピュータで動くBLASTのプログラム)

- コマンドプロンプトを立ち上げてください

スタート → すべてのプログラム → アクセサリ → コマンドプロンプト

```
C:\Users\iu>
```

- 以下、省略して

```
>
```

と記述します

- 「blastp -help」と入力して、リターン

```
> blastp -help
```

BLASTについての説明が表示されれば、OKです

stand-alone BLASTのダウンロード

- 以下のFTPサイトにアクセスします。
ftp://ftp.ncbi.nih.gov/blast/executables/LATEST

ncbi-blast-2.2.26+-ia32-linux.tar.gz	159470 KB	2012/03/03	12:23:00
ncbi-blast-2.2.26+-ia32-win32.tar.gz	50408 KB	2012/03/03	12:25:00
ncbi-blast-2.2.26+-sparc64-solaris.tar.gz	132565 KB	2012/03/03	12:24:00
ncbi-blast-2.2.26+-src.tar.gz	12606 KB	2012/03/03	12:23:00
ncbi-blast-2.2.26+-src.zip	15465 KB	2012/03/03	12:23:00
ncbi-blast-2.2.26+-universal-macosx.tar.gz	259201 KB	2012/03/03	12:25:00
ncbi-blast-2.2.26+-win32.exe			
ncbi-blast-2.2.26+-win64.exe			
ncbi-blast-2.2.26+-x64-linux.tar.gz	1369/4 KB	2012/03/03	12:24:00
ncbi-blast-2.2.26+-x64-solaris.tar.gz	129309 KB	2012/03/03	12:25:00

Windowsの場合は、
どちらかをダウンロードします




ダウンロードしたファイルをダブルクリックして、インストールします

通常は、C:\Program Files\NCBI\blast-2.2.26+ にインストールされます

細菌の全ゲノム解読

生物種	ゲノムサイズ (Mbp)	全ゲノム解読された年
<i>Haemophilus influenzae</i>	1.83	1995
★ <i>Mycoplasma genitalium</i>	0.58	1995
★ <i>Mycoplasma pneumoniae</i>	0.82	1996
.		
.		
.		
<i>Bacillus subtilis</i>	4.21	1997
<i>Escherichia coli</i>	4.67	1997
.		
★ <i>Ureaplasma parvum</i>	0.75	2000
.		
.		



◆マイコプラズマ類は、ゲノムサイズが小さいため、ゲノムプロジェクトで取り上げられることが多かった

41

デスクトップに「blast」フォルダを作成してください



```
test1.seq
test2.seq
test3.seq
Mgenitalium.faa
Mpneumoniae.faa
Ureaplasma.faa
parse-blast7.pl
```

の7つのファイルをダウンロードし、
C:\Users\%iu%\Desktop\blast
に入れてください

講義日程（平成25年度）


1. 平成25年04月09日（PC使用）

講師：大島研郎

- ▶ 130409
- ▶ Mgenitalium.faa
- ▶ Mpneumoniae.faa
- ▶ parse-blast7.pl
- ▶ test1.seq
- ▶ test2.seq
- ▶ test3.seq
- ▶ Ureaplasma.faa

42

マイコプラズマの系統学的位置



43

■ blastフォルダに移動します

```
> cd C:\Users\%iu%\Desktop\blast
```

以下のように表示されます

```
C:\Users\%iu%\Desktop\blast>
```

■ blastフォルダ内のファイルを表示します

```
> dir
```

```
2009/03/11 19:52 <DIR> .
2009/03/11 19:52 <DIR> ..
2005/04/21 23:34 222,447 Mgenitalium.faa
2005/04/21 23:33 307,006 Mpneumoniae.faa
.
.
.
```

44

データベースの準備

- 練習用にMycoplasma genitaliumゲノムデータを用います。dbフォルダの中にMgenitalium.faaというMulti-FASTAフォーマットと呼ばれる形式のファイルが置いてあります。中身を見てみましょう。

```
> more Mgenitalium.faa
```

moreコマンドについて

指定したファイルの内容を表示します。次ページを見るには [Space]キー、1行ずつ見るには[Enter]キー、終了するには[Q]キー押します。

dbフォルダ内のファイルを、メモ帳等で開いてもOKです

45

データベースの準備

- stand-alone BLASTはMulti-FASTAフォーマットのままでは、データベースとして使うことができません。BLAST用のデータベースへ変換するために以下のコマンドを実行します。

```
> makeblastdb -in Mgenitalium.faa -dbtype prot
```

-inオプション：データベース指定

-dbtype オプション：データがアミノ酸配列 (prot)

or 塩基配列 (nucl)

46

stand-alone BLASTの実行

47

- Query (質問配列) にはtest1.seqを用います

```
> more test1.seq
```

```
>gi|16130505|ref|NP_417075.1| uracil-DNA-glycosylase  
[Escherichia coli str. K-12 substr. MG1655]  
MANELTWHDLVLAEEKQQPYFLNLTQTVASERQSGVTIYPPQKDVFNFRFTELG  
DVKVVILGQDPYHGPGQAHLAFSVRPGIAIIPPSLLNMYKELENTIPGFTRPNH  
GYLESWARQGVLLNLTVLTVRAGQAHSASLWETFTDKVISLINQHREGVVFL  
LWGSQAQKKGAIIDKQRHHVVKAPHPSPLSAHRGFFGCNHFVLANQWLEQRGET  
PIDWMPVLPAAESE
```

ファイル名 (例えばtest1.seqなど) を入力するときに、「t」や「test」などを入力した後、Tabを押すことで、その文字から始まるファイル名を表示させることができます

stand-alone BLASTの実行

- test1.seqをqueryとして使い、Mgenitalium.faaデータベースに対してblastp検索を行うには、以下のコマンドを実行します。

```
> blastp -db Mgenitalium.faa -query test1.seq
```

-db : データベース指定

-query : 質問配列 (query) 指定

48

stand-alone BLASTの実行

- 検索結果をファイルとして出力するには、`-out`オプションを
使います。

```
> blastp -db Mgenitalium.faa -query test1.seq  
-out result1.txt  
> more result1.txt
```

`-out`: 出力ファイル指定

↑(上矢印)を押すと、過去に入力したコマンドが出てきます

- リダイレクトを使って出力することもできます。

```
> blastp -db Mgenitalium.faa -query test1.seq  
> result1.txt
```

49

E value設定

- E valueは、現在のデータベースにおいて、全く偶然に同じ
スコアになる配列の数の期待値であり、E valueが小さいほど
偶然には起こり得ないことを示しています。
- BLAST検索の際にE valueの閾値を設定することで、その値
よりも小さいE valueの検索結果しか出力されなくなります。
- 閾値を設定するには、`-evalue`オプションを使います。

```
> blastp -db Mgenitalium.faa -query test1.seq  
-out result1.txt -evalue 1e-10  
> more result1.txt
```

「1」と「1」の違いに注意してください

51

```
BLASTP 2.2.10 [Oct-19-2004]
Reference: Altschul, Stephen F., Thomas L. Madden, Alejandro A. Schaffer,
Jinghui Zhang, Zheng Zhang, Webb Miller, and David J. Lipman (1997),
"Gapped BLAST and PSI-BLAST: a new generation of protein database search
programs", Nucleic Acids Res. 25:3389-3402.
Query: haa:7100_TLR5: toll-like receptor 5 (A)
      (858 letters)
Database: nr-aa: Non-redundant protein sequence database Release
05-04-11      1,952,394 sequences; 634,153,439 total letters
Searching.....done
Sequences producing significant alignments:
                                     Score E
                                     (bits) Value
Top 100Top 50Top 20Top 10Top 5 Select operationCLUSTALWMAFFTPrRNDraw alignmentSearch common
motifs(pfam)Search common motifs(prosite)
sp:AB060695_1 [AB060695] Toll-like receptor 5 [Homo sapiens] 1666 0.0
sp:TLR5_HUMAN [O60602] Toll-like receptor 5 precursor (Toll/inte... 1662 0.0
sp:AX590493_1 [AX590493] Sequence 5 from Patent WO02085933; [Hom... 1659 0.0
spu:AB208697_1 [AB208697] Toll-like receptor 5 [Sus scrofa] 1303 0.0
sp:TLR5_MOUSE [Q9JLF7] Toll-like receptor 5 precursor.>prf:26102... 1203 0.0
tr:Q8CB40_MOUSE [Q8CB40] Mus musculus adult female vagina cDNA, ... 1193 0.0
tr:Q5GDA9_CHICK [Q5GDA9] Toll-like receptor 5. 866 0.0
tr:Q5GRO2_CHICK [Q5GRO2] Toll-like receptor 5 precursor.>gpu:AJ6... 848 0.0
tr:Q5U5B1_XENLA [Q5U5B1] LOC495313 protein.>gpu:BC084773_1 [BC08... 738 0.0
sp:CQ870716_1 [CQ870716] Sequence 9 from Patent EP1433792. [unid... 734 0.0
pfi:3023365a membrane-toll-like receptor - Oncothyobius mykias (... 585 e-165
tr:Q5H720_FUGRU [Q5H720] TLR5.>gpu:AC156437_1 [AC156437] TLR5 [T... 548 e-154
sp:AX590495_1 [AX590495] Sequence 7 from Patent WO02085933; [eyn... 437 e-121
tr:Q7ZT81_ONCWT [Q7ZT81] Toll-like receptor5.>gp:AB062504_1 [AB0... 366 1e-99
:
:
:
>gp:AB060695_1 [AB060695] Toll-like receptor 5 [Homo sapiens] Top
Length = 858
Score = 1666 bits (4315), Expect = 0.0
Identities = 827/844 (97%), Positives = 827/844 (97%)
Query: 15 AGVFVGIQSCSFDGRIAFVRFPCNLQVQVLMITRLLLSFNRYIRTVTASSFFFXXXXX 74
AGVFVGIQSCSFDGRIAFVRFPCNLQVQVLMITRLLLSFNRYIRTVTASSFF
Sbjct: 15 AGVFVGIQSCSFDGRIAFVRFPCNLQVQVLMITRLLLSFNRYIRTVTASSFFLQLQL 74
Query: 75 XXXGQYTLTIDKEAFENLPNLRILLDGSKKIYFLHPDAPQGLFHLFELRLYFCLGSDA 134
GQYTLTIDKEAFENLPNLRILLDGSKKIYFLHPDAPQGLFHLFELRLYFCLGSDA
Sbjct: 75 LELGQYTLTIDKEAFENLPNLRILLDGSKKIYFLHPDAPQGLFHLFELRLYFCLGSDA 134
```

質問配列の名前

検索対象として用いた
データベース

スコア

E value

アラインメント

BLASTX

- 次にblastX検索を行ってみましょう。
- test2.seqには塩基配列データが入っています。

```
> more test2.seq  
> blastx -db Mgenitalium.faa -query test2.seq  
-evalue 1e-10 -out result2.txt  
> more result2.txt
```

52

大量Queryのホモロジー検索法

- stand-alone BLASTは、Multi-FASTA形式のqueryにも対応しています。
- 例えば、下のような複数の配列を含むファイルをqueryとして用いると、それぞれをBLAST検索した結果が繋がったひとつのファイルとして出力されます。

```
>gi|49176138|ref|NP_416237.3| 6-phosphofructokinase II [Escherichia coli K12]
MVIYITLTLAPSLDSATITPQIYPEKLRCTAPVPEFGGGGIVNARIAIHLGGSATAIFPAGGATGEHLV
SLLDENVVAVTEAKDWTQRNLHVEVEASGQYRFVMPGAALNDEFRLQEEQVLEISGAILVISGSL
PPGVKLEKLTQLISAQKQGIKIRCIIVDSSEALSALAIGNIELVKPNQKELSAVNRRELTQDDVRAAQ
EIVNSGKAKRVVSLGPGQALGVDSENCIQVPPVPSQSTVGAGDSMVGAMTLKLAENASLEEMVRFV
AAGSAATLNQTRLCSHDDTQKIYAYLSR

>gi|16132212|ref|NP_418812.1| phosphoglyceromutase 2 [Escherichia coli K12]
MLQVYLVRHGETQWNAERRIQGQSDSPLTAKBQEQAMQVATRAKELGITHIISDLGTRTRTAEIIAQAC
GCDIIFDSRLRELNMVLEKRHIDSLTEEENWRRLVNGTVDRIPESGESMQELSDRVNALESRCRDL
PQGRPLLVSHGIALGCLVSTILGLPAWAERRLRNCSISRVDYQESLWLASGMVVTAGDISHLDPAL
DELQR

>gi|16131851|ref|NP_418449.1| glucosephosphate isomerase [Escherichia coli K12]
MKNINPTQTAAWALQKHFDEMKDVTIADLFAKDGDRFSPKFSATFDDQMLVDYSKNRITTEETLAKLQDLA
RECDLAGALIKSMPGSEKINTEKAVLLEALNRNSNPTLVDGKQVMPFVMAVLEKRTFSEAIISGEWK
GYTKAALTDVNIIGGGDLGPMVTEALRPFYKHLNMFVSNVDGTHIASVILKYNPETTLFLVASKTF
TTQETMTNAHSARDWFLKAAGDEKHVAKHPAALSTNAKAVGEPGIDTANMPEFMDWVGGQYSLMSAIGLS
IVLSIGFDNFVELLSGAHAMDKHFTTAEKNLPLVLLALIGIWNFFGAEATEAILFPDQYMRFAAYFQ
QNMESNGKYVDRNGNVVYQTPGIWGEFGTNGQAFYQLIHQGTVMVPCDFIAPAITNPLSDHHQKL
LSNFFAQTEALAFGKSRVVEQEYRDQKDPATLDYVVPFKVFEGRNPTNSILLREITPFLSALGIALY
HKIFTQGVILNIFTFDQWVLELQLANRILPELKDDEKISSHSDSTNGLINRYKAWRG
```

53

大量Queryのホモロジー検索法

- test3.seqには、100個分のアミノ酸配列がMulti-FASTAフォーマットで記述してあります

```
> more test3.seq
```


- これらと相同なアミノ酸配列がMgenitalium.faa内にあるかどうかを調べるために、以下のコマンドを実行してください

```
> blastp -db Mgenitalium.faa -query test3.seq
-evalue 1e-10 -out result3.txt
> more result3.txt
```

54

ホモロジー検索を用いた比較ゲノム解析

- アミノ酸配列が類似したタンパク質は、機能も似ていることが推測されます
- このような、非常に類似性が高く、おそらく共通の祖先遺伝子から派生したと考えられるタンパク質をコードする遺伝子のことを、「オーソログ遺伝子」と呼びます
- 片方の生物種の遺伝子（あるいはアミノ酸）配列をqueryとして用いて、相手のゲノムに対してホモロジー検索を行うことで、オーソログ遺伝子を同定できます



55

ホモロジー検索による比較ゲノム

- Mpneumoniae.faaには、Mycoplasma pneumoniaeがゲノムにコードする全アミノ酸配列がMulti-FASTAフォーマットで記述してあります

```
> more Mpneumoniae.faa
```

- これらと相同なアミノ酸配列がMgenitalium.faa内にあるかどうかを調べるために、以下のコマンドを実行してください

```
> blastp -db Mgenitalium.faa -query Mpneumoniae.faa
-evalue 1e-10 -out result4.txt
> more result4.txt
```

56

perlを用いたデータ処理

- 大量のQueryに対してBLAST検索を行うと、結果が羅列した形で出力されます
- Perlなどのプログラミング言語を用いることで、この中から、必要な情報だけを取り出すことができます
- Queryのアクセス番号や、検索の結果ヒットしたタンパク質の情報などのリストを作成してみましょう

Query GI	ref.No.	Function	Length	Score	E-value	Identity
16132212	NP_014926.1	Yor283wp	230	62.8	4.00E-11	48%
16131851	NP_009755.1	Glucose-6-phosphate isomerase; Pgil p	554	641	0	73%
16131757	NP_010335.1	triosephosphate isomerase; Tpi1 p	248	192	4.00E-50	60%
16131754	NP_011756.1	phosphofructokinase alpha subunit; Pfk1 p	987	184	2.00E-47	51%
16131018	NP_009362.1	Pyruvate kinase; Cdc19p	500	40.8	2.00E-04	50%
16130827	NP_008938.1	3-phosphoglycerate kinase; Pgk1 p	416	255	7.00E-69	57%
16130826	NP_012863.1	aldolase; Fbat p	359	352	4.00E-98	88%
16130686	NP_011770.1	enolase I; Eno1 p	437	359	1.00E-100	62%
16130106	NP_009865.1	ribo kinase; Rtk1 p	333	35.4	0.012	59%
16129807	NP_009362.1	Pyruvate kinase; Cdc19p	500	247	3.00E-66	49%
16129733	NP_012483.1	Glycerol dehydrogenase	332	427	1.00E-120	77%

57

BLASTP 2.2.5 [Nov-16-2002]

Reference: Altschul, Stephen F., Thomas L. Madden, Alejandro A. Schaffer, Jinghui Zhang, Zheng Zhang, Webb Miller, and David J. Lipman (1997), "Gapped BLAST and PSI-BLAST: a new generation of protein database search programs", Nucleic Acids Res. 25:3389-3402.

Query= gi|16131851|ref|NP_418449.1| glucosephosphate isomerase [Escherichia coli K12] (549 letters)

Database: yeast.aa
6298 sequences; 2,974,038 total letters

Sequences producing significant alignments:	Score	E (bits)	Value
ref NP_009755.1 Glucose-6-phosphate isomerase; Pgilp	641	0.0	
ref NP_011646.1 Ygr130cp	30	0.98	
ref NP_013146.1 spindle pole body component; Stu2p	29	1.7	
ref NP_013847.1 (putative) involved in cell wall biogenesis; Ec...	28	3.7	
ref NP_013523.1 Ylr419wp	28	3.7	

>ref|NP_009755.1| Glucose-6-phosphate isomerase; Pgilp
Length = 554

Score = 641 bits (1654), Expect = 0.0
Identities = 326/549 (59%), Positives = 401/549 (73%), Gaps = 16/549 (2%)

Query: 7 TQTAAWQALQKHDEM-KDVTIADLFAKGDGRFSKFSATFDD---QMLVDYSKNRITEE 61
+ + AW LQK ++ K +++ F KD RF K + TF + ++L DYSKN + +E
Sbjct: 13 TELPAWSKLQKIYESQGKTL SVKQEFQDKAKRFKLNKTFITNYDGSKILFDYSKNLVNDE 72

Query: 62 TLAKLQDLAKECDLAGAIAKSMFSGEIKINRTENRAVLHVALRNRNTPILVDGKDVMEPVN 121
+A L +LAKE ++ G +MF GE IN TE+RAV HVALRNR+N P+ VDG +V PEV+
Sbjct: 73 IIAALIELAKEANVTGLRDAMPKGEHINSTEDRAVYHVALRNRANKPMYVDGYNVAPEVD 132

58

- "Query=" で始まる行に質問配列の情報が、">"で始まる行にヒットした遺伝子の情報が書かれています。
- これらの行だけを抜き出して表示するプログラムparse-blast7.plを用意しておきました。

```
> more parse-blast7.pl
```

parse-blast.pl

```
#!/usr/local/bin/perl

use strict;
use warnings;
use Getopt::Std;

my $mode = 0;
my $name = "";
.
```

- Perlのプログラミングについては、次回の講義で扱います。

59

- 以下のコマンドを入力し、result4.txtを処理して、list1.txtを生成します。

```
> perl parse-blast7.pl -i result4.txt -o list1.txt
```

「スタート」

すべてのプログラム

「list1.txt」をExcel上に
ドラッグ & ドロップ

Microsoft Office → Microsoft Office Excel

質問配列の情報		BLAST検索でヒットした配列の情報 (ヒットしなかった場合は空欄)					
Query GI	Query	Hit_ref.No.	Hit_Function	Hit_Length	Score	E-value	Identity
gi 13507740	DNA polymerase III beta subu...	NP_072661.1	DNA polymerase III, subunit b...	364	516	1.00E-148	70%
gi 13507741	similar to J-domain of DnaJ[M...	NP_072662.1	dnaJ-like protein [Mycoplasma...	310	437	1.00E-125	83%
gi 13507742	DNA gyrase subunit B [Mycoc...	NP_072663.1	DNA gyrase subunit B (gyrB)	650	1184	0	86%
gi 13507743	DNA gyrase subunit A [Mycoc...	NP_072664.1	DNA gyrase subunit A (gyrA)	836	1330	0	84%
gi 13507744	seryl-tRNA synthetase [Mycoc...	NP_072665.1	seryl-tRNA synthetase (serS)	417	669	0	76%
gi 13507745	thymidylate kinase [Mycoplasma...	NP_072666.1	thymidylate kinase (tmk) [Myc...	210	280	1.00E-77	62%
gi 13507746	similar to DNA-polymerase su...	NP_072667.1	hypothetical protein MG007 [254	281	4.00E-78	72%
gi 13507747	thiophene and furan oxidator...	NP_072668.1	thiophene and furan oxidator...	442	573	1.00E-166	63%
gi 13507748	hydrolase [Mycoplasma pneur...	NP_072669.1	hypothetical protein MG009 [262	365	1.00E-103	64%
gi 13507749	hypothetical protein MPN01 0...						
gi 13507750	hypothetical protein MPN01 1...						
gi 13507751	hypothetical protein MPN01 2...						
gi 13507752	hypothetical protein MPN01 3...						
gi 13507753	hypothetical protein MPN01 4...	NP_072670.1	hypothetical protein MG01 0 [218	230	9.00E-63	70%
gi 13507754	hypothetical protein MPN01 5...	NP_072671.1	hypothetical protein MG01 1 [287	325	3.00E-91	82%
gi 13507755	similar to ribosomal S6modific...	NP_072672.1	hypothetical protein MG01 2 [287	368	1.00E-104	62%

M. genitaliumに
これらと相同なタンパク質が
コードされていない

<課題>

- *Ureaplasma faa*には、*Ureaplasma parvum*ゲノムにコードされる全タンパク質がMulti-FASTAフォーマットで記述してあります
- 「Mpneumoniae.faa」をデータベース、「*Ureaplasma faa*」を質問配列として用いてBLAST検索を行い、*Ureaplasma*がコードするタンパク質と相同なものが*M. pneumoniae*ゲノム上にもあるかどうか、調べてください（E-valueの閾値は、 $1e-3$ に設定してください）
- parse-blast7.plを使って、ヒットしたアミノ酸配列のリストを作成してください。
- 作成したエクセルファイルを提出してください。

61

「受講生の方へ」のページ

↓
「課題提出用Web mailページへ（講義室のみからアクセス可）」

送信先: kenro@hosei.ac.jp ← kenro@hosei.ac.jpを選ぶ

件名: BLAST課題 ← 「BLAST課題」と入力

氏名: _____

所属: _____

学生証番号: _____


E-mail: _____ Ccを送る

本文: _____ ← 本日の講義の感想を、ご記入ください

添付ファイル: 次の確認画面で指定して下さい

62

- ◆ *Ureaplasma* はウレアーゼを用いて尿素を分解し、その結果生じたプロトン濃度勾配を利用して、約95%のATPを合成する



Query_Cd	Query	Hit_ref.No.	Hit_Function
g 1335798	urease complex component[Ureaplasma parvum]		
g 1335798	urease complex component[Ureaplasma parvum]		
g 1335798	urease complex component[Ureaplasma parvum]		
g 1335798	urease complex component[Ureaplasma parvum]		
g 1335799	urease subunit alpha [Ureaplasma parvum se rovar]		
g 1335799	urease complex component[Ureaplasma parvum]		
g 1335798	urease complex component[Ureaplasma parvum]		
g 1335798	ferrichrome transport ATP-binding protein [Ureaplasma parvum]	NP_1109882.1	cobalt transport ATP-binding protein [Mycobacterium tuberculosis]
g 1335799	hemolysin [Ureaplasma parvum se rovar 3 str. ATC]		
g 1335800	hypothetical protein UU437 [Ureaplasma parvum]	NP_110226.1	UV protection protein MucB [Mycoplasma pneumoniae]
g 1335800	hypothetical protein UU437 [Ureaplasma parvum]	NP_110225.1	Holiday junction DNA helicase RuvB [Mycobacterium tuberculosis]

ウレアーゼは、*Ureaplasma*ゲノムにだけコードされていることがわかる

63