

2014年度「理論分子生物学」講義予定表


- ◆ ゲノム解析・オミックス解析とバイオインフォマティクス
- ◆ 配列アライメント：ダイナミックプログラミング法
- ◆ ホモロジー検索：FASTA、BLASTアルゴリズム
- ◆ マルチプルアライメント、系統樹解析
- ◆ 配列モチーフ
- ◆ 二次構造予測、膜貫通部位予測、立体構造予測
- ◆ 遺伝子の機能アノテーション、比較ゲノム解析
- ◆ メタゲノム解析
- ◆ ネットワーク解析
- ◆ 分子生物学データベース
- ◆ 演習

- ◆ <http://goto.kuicr.kyoto-u.ac.jp/lecture/bioinfo.html>

配列アライメント

- ◆ 配列アライメント (sequence alignment)
 - 2つのタンパク質または遺伝子の配列を並べて、**進化的**な関連があるかどうかを調べること
- ◆ 2つの遺伝子が進化的に関連があるか？
 - 異なる生物種間で同じ**機能**を持つ遺伝子
 - 一つの生物種内で類似した**機能**を持つ遺伝子
- ◆ 異なる生物種で同じ機能の遺伝子を比較する
 - 生物種間の進化的な関係

生物種の系統関係



ウーズらによる進化系統樹
分子レベル（配列レベル）の情報：16S rRNA



オーソログとパラログ

ホモログ (Homolog)
進化的な起源を同じくする遺伝子

オーソログ (Ortholog)
種分岐の際に同じ遺伝子だったもの
通常同じ機能を持つ

パラログ (Paralog)
遺伝子重複によってできた類似遺伝子
通常異なる機能を持つ

ゼノログ (Xenolog)
水平移動によって得られた類似遺伝子



配列アライメント

◆ 配列アライメント (alignment)

- 2つのタンパク質または遺伝子の配列を並べて、**ホモログ（相同）**かどうかを調べること
- 実際には類似性を調べる
- 文字の一致（マッチ）、不一致（ミスマッチ）、挿入、欠失を考慮する

◆ アライメントのキーポイントは

- アライメントの種類
- アライメントの方法・アルゴリズム
- アライメントを評価するためのスコア
- スコアの重要性を評価するための統計的基準

配列アライメントの種類

◆グローバルアライメント

- 配列全体を並べる

```
LGPSSKQTGKGW-SRIWDN
|   +|   |||   |+ |
LN-ITKSAGKGAIMRLGDA
```

マッチ (+, |)
ミスマッチ
ギャップ・挿入 (-)

◆ローカルアライメント

- 局所的によく似た部分を探す

```
-----TGKG-----
      |||
-----AGKG-----
```

アライメント方法の種類

◆ 2本の配列のアライメント

■ ペアワイズアライメント

- ◆ ドットマトリックス
- ◆ ダイナミックプログラミング
- ◆ ワードを使った方法



◆ 3本以上の配列のアライメント

■ マルチプルアライメント

- ◆ 累進法
- ◆ 反復改善法

ドットマトリックス


- ◆ 比較する配列を行列の行と列に並べて一致する文字に対応する行列成分にドットをうつ
- ◆ 類似部分をマトリックスの対角成分として表示
- ◆ 同一配列をマトリックス表示するとリピート部分も抽出できる




<http://www.tulane.edu/~biochem/lecture/723/seqalign.html>

ドットマトリックス

二つのバクテリアの EF-G (転写伸長因子) の例
S. aureus (黄色ブドウ球菌) と *T. thermophilus* (好熱菌)



タンパク質アミノ酸配列



DNA塩基配列


<http://www.tulane.edu/~biochem/lecture/723/seqalign.html>

Entry	SA0505
Gene name	fus
Definition	elongation factor EF-G [EC:3.6.5.3]
Orthology	KO: K02355 elongation factor EF-G
Class	BRITE hierarchy
SSDB	Ortholog Paralog
Motif	Pfam: GTP_EFTU PROSITE: EFAC Motif
Other DBs	NITE: SA0505 NCBI-GI: 1592 NCBI-GeneID: P687 UniProt: P687
LinkDB	PDB All DBs
Position	588492..59057
AA seq	693 aa AA seq MAREFSLEKTRNI ITITSAATTAWE RQATTYGVPRIVF MKCFKYTNDLGTE KEAIRQATTNVEF AKADDSAEFAALA NSRQEIDTVYSGD DKMTQALVKLQEE SYRETFKSSAQVQ VEAGLKDAMENGV LEPMMKVVTIEMPE NTQGRGTYTMYFD

Entry	tlr1749	CDS	T.elongatus
Gene name	fus		
Definition	translation elongation factor EF-G [EC:3.6.5.3]		
Orthology	KO: K02355 elongation factor EF-G		
Class	BRITE hierarchy		
SSDB	Ortholog Paralog Gene cluster		
Motif	Pfam: GTP_EFTU MMR_HSR1 Miro GTP_EFTU_D2 EFG_IV EFG_C PROSITE: EFACTOR_GTP Motif		
Other DBs	CYORF: tlr1749 Kazusa: tlr1749 NCBI-GI: 22299292 NCBI-GeneID: 1011972 UniProt: Q8DI43		
LinkDB	PDB All DBs		
Position	1829639..1831714	Genome map	
AA seq	691 aa AA seq DB search MARTTPLERVRNIGIAAHIDAGKTTTTTERILFYSGVVHKIGEVHEGTTVTDWMEQERERG ITITAAAISTSWRDHQINIIDTPGHVDFTIEVERSMRVLDGVIAVFCVGGVQPQSETVW RQADRYSVPRIVFVNKMDRTGANFYKVHDQIRDRLRANAVPIQLPIGAEDQFKGIVDLVR MRAKIYKDDLGEIEDTEIPAEMTELAQEYRTKLEIAVAETDDALMEKYFEGEELTEEEI RAALRKGTIAGTIVPMLCGSAFKNKGVQLLLDAVVDYLPAPIDIPAIGRLPDGTEVERA ADDDQPLAALAFKIMSDPYGRLTFVRVYSGVLKKGSYVLNATKGKKERISRLIVLKADER IEVDELRAAGDLGAALGLKETFTGDTLCESSPVILESLEYIPEPVISVAVEPKTKQDMEKL SKALQALSEEDPTFRVSVDPETNQTVIAGMGELHLEILVDRMQREYKVEANIGQPQVAYR ETIRKPVRAEGKFIRQSGGKGQYGHVVIEVEPAEPGTGFEFVSKIVGGVVPKEYIPPAEQ GMKEACESGILAGYPVIDLKVTLVDGSYHEVDSSEMAFKIAGSIAIKEAVMKANPVLLEP MMKVEVEVPPEEFLGTVMGDLIARRGQIEGQTVENGIKAKVTAKVPLERMFGYATDIRSNTQ GRGIFSMESHYEEVPRNVAEAIIAKNKGNA		

NT seq	2082 nt NT seq +upstream 0 nt +downstream 0 nt	
atggctagagaatt gctggtaaacgac ggtgaaacacacga attactatcacatc gatacacctggaca ggagcagttacagt cgtcaggctacaac ggtgctaacttcga ccaatccaattacc atgaaatgtttcaa gaagaccacttaga actagcgacgaatt aaagaagctatccg gctttcaaaaacaa ccactagacgttaa gcgaaagcagacga tatgttggtaaatt gttaagaactctac aactcacgtcaaga aaagatacaggtac atggaattcccaga gataaaatgactca actgacgaagaac ttagtagaccgtat tcatatcgtgaaac ggtggctcgtggtca ggtttcgaattcga gtagaagctggtct gatgttaaagctaa ttcaaaattgctgc ttagaaccaatgat ggtgacgtaacatc gttgttaatgctta aacactcaaggtcg tcaatcgtgaaga	NT seq 2076 nt NT seq +upstream 0 nt +downstream 0 nt gtggcacggacgaccccgctagagcgagtgcgaaatatcgggattgccgctcacattgat gcgggtaaaacaaccacaactgaacgtattctcttctattccggtgtggtgcacaaaatt ggtgaagtgcacgaggggaccacggttaccgactggatggaacaggagcgagagcggggc atcaccattacagcagccgccattagcacctcttgagagatcaccaaatacaacattatt gacactcccggccacgtggacttcacgattgaggtggagcgctccatgccccgttctcgat ggggtgattgcggtattctgctccgttggtggtgtgcagcccaatcagaaaccgtgtgg cggcaagccgatcgctacagcgttccccgcacgtttttgtcaacaagatggatcgacg ggggcaaacttctacaaagtccatgaccagattcgcgatcgccacggcggaacgccgtg ccgattcagttgccattggtgctgaagatcaattcaaaggcatcggtgatctggtgcgc atgcgcgccaaaatctacaaagacgaccttggaaggaaatcgaagacactgaaattcct gccgagatgactgaactggcacaggagatcgcaccaagctcatcgaggctgttgccgaa accgacgacgccctcatggaaaaatacttcgagggggaagaactcacagaagaggaaatc cgtgcggctctacgcaaaggacgatcgctggcaccattgtgccatgctttgcggctct gccttcaaaaataaaggcgtgcaattactcctggatgccgtggtggactacctaccggcg ccattgacattcctgccattaaaggctcgtctgcccgatggcacagaagtggagcgggct gccgatgacgatcaaccctggcggcactcgcttttaagatcatgtcggatccctatggc cgctttacctttgtgctgtttattccgggtgttctgaaaaaggtagctatgtgctcaat gccaccaagggaagaaagagcgcatcttctcgtctaatacgtgctgaaggccgatgaacgg attgaggtggatgaattgcgagctggcgatctaggagctgccttaggtctcaaggaaacc ttcacaggggataccctctgcgatgaaagctcgcccgatgattcttgagtcgctgtatatt ccagagccagttatttccgtggccgtagaaccctaaacaggacatggaaaagctc tccaaggctctgcaagccctctctgaggaggacccaccttccgcgtcagcgttgatcct gaaacgaaccaaacctgattgcgggaatgggggaactacacctcgagattcttgtggat cggatgcagcgggagtagaaagtgaagccaacatcgccaaccccaagtggcttaccgc gaaaccattcgcaaaccctccgggctgaaggcaagtttatccgtcaaagtgggtggtaaa ggtcagtatggtcacgttggtattgaagtgaacctgctgaacccggtactgggtttgaa tttgtctccaaaattgtcgggtggtgctgacccaaagagtacattccaccgcgtgagcag gggatgaaggaagcctgtgaatcggggattttggcagggtagccagtgattgacctcaa gtcacactagtggatggctcctaccacgaggtggactcctcagagatggctttcaaaatt gctggctccatcgccattaaagaggcagtcagaaagccaatccagtagctggtggagcca atgatgaaggctcgaggtcgaggttcagagaagaattccttgggacagtgatgggagatcta attgcccgtcgcggtcaaattgagggacaaaccgtagaaaatggcattgccaaagtgcg gcaaaagttcctctcgaacggatgtttggttatgccactgacattcgctcgaatacccaa ggtcgggggaattttctcgatggaatttagccattacgaggaagtccccgtaatgtggct gaggcgatcattgccaaaaataaagggaacgcatag	

ワードサイズによる評価




1文字ずつ比較して、
一致するところに
ドット

3文字ずつ比較して、
完全一致するところ
にドット

3文字ずつ比較して、
そのうち2文字一致
するところにドット

ワードサイズによる評価




ワードサイズ 23、閾値 5（23文字のうち5文字）の
マッチでドット

ドットマトリックスによるリピート同定

human LDL (low density lipoprotein) receptor

hsa:3949



EGF_CA:
calcium binding EGF domain
タンパク質間相互作用に必要

<http://www.blc.arizona.edu/courses/bioinformatics/matrix-lect.html>

アライメント方法の種類

◆ 2本の配列のアライメント

■ ペアワイズアライメント

- ◆ ドットマトリックス
- ◆ ダイナミックプログラミング
- ◆ ワードを使った方法

◆ 3本以上の配列のアライメント


■ マルチプルアライメント

- ◆ 累進法
- ◆ 反復改善法

ダイナミックプログラミング (DP)

ドットマトリックスでは対角線成分だけ

→ ギャップも考慮したい (塩基の挿入・欠失)




全パターンの並べ方から最適なものを探し出す問題

全パターン


左上から右下まで辿る経路
縦と横の矢印がギャップ

アライメント AIM-S
 A-MOS

ダイナミックプログラミング (DP)




DP計算用の行列D



評価関数による枝刈り

評価関数（スコア）の計算方法



$$D_{i,j} = \max \left(\begin{array}{l} D_{i-1,j-1} + w_{s(i),t(j)}, \\ D_{i-1,j} + d, \\ D_{i,j-1} + d \end{array} \right)$$

	1	2	3	4
文字列 s	A	I	M	S
文字列 t	A	M	O	S

$w_{s(i),t(j)}$:

アミノ酸の場合、 $s(i)$ と $t(j)$ の類似度

塩基配列の場合、通常マッチ 1，ミスマッチ 0

d : ギャップペナルティ

グローバルアライメント

ニードルマンとブンシュによる評価関数の計算方法

$$D_{0,0} = 0$$

$$D_{i,0} = i d$$

(for $i = 1$ to n)

$$D_{0,j} = j d$$

(for $j = 1$ to m)

$$D_{i,j} = \max \left(\begin{array}{l} D_{i-1,j-1} + w_{s(i),t(j)}, \\ D_{i-1,j} + d, \\ D_{i,j-1} + d \end{array} \right)$$

		A	T	A	T	G	C	C	T	T
	0	-1	-2	-3	-4	-5	-6	-7	-8	-9
A	-1	1	0	-1	-2	-3	-4	-5	-6	-7
A	-2	0	1	1	0	-1	-2	-3	-4	-5
G	-3	-1	0	1	1	1	0	-1	-2	-3
C	-4	-2	-1	0	1	1	2	1	0	-1
C	-5	-3	-2	-1	0	1	2	3	2	1
T	-6	-4	-2	-2	0	0	1	2	4	3
G	-7	-5	-4	-2	-1	1	0	1	3	4
T	-8	-6	-4	-3	-1	0	1	0	2	4

ここでは $d = -1$ で計算
max の計算で使った経路を覚えておく

グローバルアライメント

ニードルマンとブンシュによる評価関数の計算方法

$$D_{0,0} = 0$$

$$D_{i,0} = i d$$

(for $i = 1$ to n)

$$D_{0,j} = j d$$

(for $j = 1$ to m)

$$D_{i,j} = \max \left(\begin{array}{l} D_{i-1,j-1} + w_{s(i),t(j)}, \\ D_{i-1,j} + d, \\ D_{i,j-1} + d \end{array} \right)$$

ATATGCCT-T
A-A-GCCTGT

		A	T	A	T	G	C	C	T	T
	0	-1	-2	-3	-4	-5	-6	-7	-8	-9
A	-1	1	0	-1	-2	-3	-4	-5	-6	-7
A	-2	0	1	1	0	-1	-2	-3	-4	-5
G	-3	-1	0	1	1	1	0	-1	-2	-3
C	-4	-2	-1	0	1	1	2	1	0	-1
C	-5	-3	-2	-1	0	1	2	3	2	1
T	-6	-4	-2	-2	0	0	1	2	4	3
G	-7	-5	-4	-2	-1	1	0	1	3	4
T	-8	-6	-4	-3	-1	0	1	0	2	4

右下（右端）から覚えていた経路を
辿って戻る（バックトラック）

ローカルアライメント

スミスとウォーターマンによる評価関数の計算方法

$$D_{0,0} = 0$$

$$D_{i,0} = 0$$

(for $i = 1$ to n)

$$D_{0,j} = 0$$

(for $j = 1$ to m)

$$D_{i,j} = \max \left(\begin{array}{l} D_{i-1,j-1} + w_{s(i),t(j)}, \\ D_{i-1,j} + d, \\ D_{i,j-1} + d, \\ 0 \end{array} \right)$$


ATGCCT-T
AAGCCTGT

		A	T	A	T	G	C	C	T	T
		0	0	0	0	0	0	0	0	0
A		0	1	0	1	0	0	0	0	0
A		0	0	1	1	1	0	0	0	0
G		0	0	0	1	1	2	1	0	0
C		0	0	0	0	1	1	3	2	1
C		0	0	0	0	0	1	2	4	3
T		0	0	1	0	1	0	1	2	5
G		0	0	0	1	0	2	1	1	4
T		0	0	1	0	2	1	2	1	3

スコア最大の箇所から覚えていた経路を辿って戻る (バックトラック)


アミノ酸の構造と類似度

Glycine (Gly)




C00037

Alanine (Ala)




C00041

Valine (Val)




C00183

Leucine (Leu)




C00123

Isoleucine (Ile)




C00407

Aspartate (Asp)




C00049

Asparagine (Asn)




C00152

Glutamate (Glu)




C00025

Glutamine (Gln)




C00064

Serine (Ser)




C00065

Threonine (Thr)




C00188

Methionine (Met)




C00073

Cysteine (Cys)




C00097

Lysine (Lys)




C00047

Arginine (Arg)




C00062

Histidine (His)




C00135

Proline (Pro)




C00148

Phenylalanine (Phe)




C00079

Tyrosine (Tyr)



C00082

Tryptophan (Trp)



C00078

- 疎水性、親水性
- 電荷の有無
- 残基のサイズ
- コドン使用パターン

PAM (Accepted Point Mutations)

◆ デイホフらによる定式化 (1978年)

- 71 **グループ**の配列：類似度が 85% 以上
- 1,572 の置換をカウント
- 各アミノ酸置換の確率を1,572 の置換の割合で求める
- 対数尤度 (Log odds) 比で表現
 - ◆ $\log_{10}(q_{ij}/p_i p_j)$ に比例したスコア
 - ◆ p_i はその文字の出現率、 q_{ij} は同時出現率
- PAM 1
- PAM 250 は PAM 1 を250 回掛け合わせたもの
 - ◆ 20 % の類似度に相当する

BLOSUM (*BLO*ck *SU*bstitution Matrices)

◆ ヘニコフらによる定式化 (1992年)

- ギャップなしのローカルアライメントのデータベース (ブロック) から計算
- すべての置換頻度と非置換頻度 (すべてのアミノ酸ペア $20 \times 19 / 2 = 210$ パターン) をカウント
- 対数尤度 (Log odds) 比を使うのはPAMと同じ
 - ◆ $\log_2(q_{ij}/p_i p_j)$ に比例したスコア
 - ◆ p_i はその文字の出現率、 q_{ij} は同時出現率
- 70% 一致、60% 一致など配列一致度ごとに作成したブロックを用いてそれぞれの置換行列を計算

ギャップペナルティの種類


◆ 線形スコア

- 長さ g のギャップペナルティ
- $r(g) = -gd$

◆ Affine スコア

- 長さ g のギャップペナルティ
- $r(g) = -d - (g - 1)e$
- d : gap open penalty
- e : gap extension penalty
- 通常は $d > e$

アフィンスコアを使った DP



スコアの重要性を評価するための統計的基準

◆ ランダム配列との比較

■ Z-score

$$Z = \frac{S - \mu}{\sigma}$$

S : スコア


μ : 平均

σ : 分散

練習問題

アミノ酸配列 GKYD と GFVD のローカルアライメントを、ギャップペナルティに2 ($d=-2$) を、アミノ酸置換行列にBLOSUM50 を使って作成しなさい。

$$D_{i,j} = \max \left(\begin{array}{l} D_{i-1,j-1} + w_{s(i),t(j)}, \\ D_{i-1,j} + d, \\ D_{i,j-1} + d, \\ 0 \end{array} \right)$$



文献

- ◆ Woese, C. R., Kandler, O. and Wheelis, M. L. (1990) Towards a natural system of organisms: Proposal for the domains, Archaea, Bacteria and Eukarya. *Proc. Natl. Sci. USA*, 87, 4576-4579.
- ◆ Gibbs, A. J. and McIntyre, G. A. (1970) The diagram, a method for comparing sequences. Its use with amino acid and nucleotide sequences. *Eur. J. Biochem.*, 16, 1-11.
- ◆ Needleman, S. B. and Wunsch, C. D. (1970) A general method applicable to the search for similarities in the amino acid sequence of two proteins. *J. Mol. Biol.*, 48, 443-453.
- ◆ Smith, T. F. and Waterman, M. S. (1981) Identification of common molecular subsequences. *J. Mol. Biol.*, 147, 195-197.
- ◆ Gotoh, O. (1982) An improved algorithm for matching biological sequences. *J. Mol. Biol.*, 162, 705-708.
- ◆ Dayhoff, M. O., Schwartz, R. M. and Orcutt, B. C. (1978) A model of evolutionary change in proteins. In *Atlas of Protein Sequence and Structure*, Vol. 5, Suppl. 3, pp. 345-352.
- ◆ Henikoff, S. and Henikoff, J. G. (1992) Amino acid substitution matrices from protein blocks. *Proc. Natl. Acad. Sci. USA*, 89, 10915-10919.