

# 2015年度「バイオインフォマティクス」 講義予定表

- ◆ 配列アライメント
- ◆ データベースサーチ
- ◆ タンパク質機能・立体構造予測
- ◆ 配列モチーフ・隠れマルコフモデル
- ◆ メタゲノム解析（緒方）
- ◆ 分子進化・分子系統解析（緒方）
- ◆ 遺伝子予測（緒方）
- ◆ 機能アノテーション・比較ゲノム（緒方、五斗）
- ◆ システムズバイオロジー演習（五斗）

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

# 配列モチーフ

## ◆ 機能ドメイン（機能部位）

- 機能的, 構造的に重要な部位は進化の過程で保存される傾向がある
- 進化的に保存されたドメイン

## ◆ 配列モチーフ

- 機能ドメイン中の特徴的な *保存配列パターン*
- マルチプルアライメントから抽出

## ◆ 配列モチーフの表現方法

- パターン
- プロファイル

## 機能ドメインの例

### ◆ タンパク質

- ペプチド鎖切断部位
- リン酸や糖鎖などの修飾部位
- シグナル配列
- DNA結合部位、リガンド結合部位

### ◆ RNA

- スプライス部位：GU/AGルール
- 翻訳開始点

### ◆ DNA

- 複製開始点
- プロモーター

ENCODE

## 機能ドメインの例

### ◆ 亜鉛フィンガー DNA 結合部位

- PROSITE パターンの例
- C-x(2,4)-C-x(3)-[LIVMFYWC]-x(8)-H-x(3,5)-H.



[http://www.genome.jp/dbget-bin/www\\_bget?prosdoc:PDOC00028](http://www.genome.jp/dbget-bin/www_bget?prosdoc:PDOC00028)

# ドメインからモチーフの抽出

## マルチプルアライメント

### Triose phosphate isomerase (TIM) の活性部位

E.coli	EEVCARQIDAVLKT-----QGAAAFEGAVIAYEPVWAIGTGISATPAQA
H.influenzae	EEVCARQIDAVINA-----LGVEAFNGAVIAYEPIWAIGTGISATPAQA
X.fastidiosa	EAILRAQLEPVLSL-----VGSAGFARAVIAYEPIWAIGTGISATPDQA
Buchnera	EQVIQRQLNLILKN-----LGTSAFKNIIAYEPIWAIGTGISADPEHV
S.aureus	NDVVGEQVKKAVAG-----LSEDQLKSVVIAYEPIWAIGTGISSTSEDA
A.thaliana	MDVVAAQTKAIADR-----VTN--WSNVVIAYEPVWAIGTGISVASPAQA
H.pylori	FKAVKEFLSEOLEN-----IDLN-YPNLVIAYEPIWAIGTKISASLEDI
T.whipplei	LSRFRSVLSHLKAISDKKHSIGYALGSKTHFLDSDQLHMLIAYEPSSAINSGICANSGLI
	. : ***** **.: :

A-Y-E-P-[IVS]-[WS]-A-I-[GN]-[TS]-[GK]  
配列パターン

A.thaliana QEVHDELKWLAKNVSAATTRIIYGGSVNGGNCKELGGQADVDGFLVGGASLKP-EF

データベースに登録されている配列パターンは

[AVG]-[YLV]-E-P-[LIVMEPKST]-[WYEAS]-[SAL]-[IV]-[GN]-[TEKDVS]-[GKNAD]

[http://www.genome.jp/dbget-bin/www\\_bget?prosite:PS00171](http://www.genome.jp/dbget-bin/www_bget?prosite:PS00171)

## 配列パターン

- ◆ 保存配列をアミノ酸のパターンとして表現
  - 正規表現による表現方法
    - ◆ 文字列の集合を一つの文字列で表現する方法
  - 例
    - ◆  $[AV]-Y-E-P-[LIVM]-W-[SA]-I-G-T-[GK]$
    - ◆  $C-x(2,4)-C-x(3)-[LIVMFYWC]-x(8)-H-x(3,5)-H$
  - $x$ : 任意のアミノ酸
  - $x(2,4)$ : 任意のアミノ酸が2~4個続く
  - $[ ]$ : この中のアミノ酸のどれか
  - $\{ \}$ : この中のアミノ酸以外のどれか
- ◆ 見た目に分かりやすいが、アミノ酸の出現頻度情報は失われてしまう

# PROSITE でのパターン表現

```
ID    TIM; PATTERN.
AC    PS00171;
DT    APR-1990 (CREATED); DEC-2004 (DATA UPDATE); JUN-2007 (INFO UPDATE).
DE    Triosephosphate isomerase active site.
PA    [AVG]-[YLV]-E-P-[LIVMEPKST]-[WYEAS]-[SAL]-[IV]-[GN]-[TEKDVS]-[GKNAD].
NR    /RELEASE=53.3,274295;
NR    /TOTAL=236(236); /POSITIVE=236(236); /UNKNOWN=0(0); /FALSE_POS=0(0);
NR    /FALSE_NEG=9; /PARTIAL=4;
CC    /TAXO-RANGE=A?EP?; /MAX-REPEAT=1;
CC    /SITE=3,active_site;
CC    /VERSION=1;
DR    P36204, PGKT_THEMA , T; P36186, TPI1_GIALA , T; P36187, TPI2_GIALA , T;
DR    Q9SKP6, TPIC_ARATH , T; Q9M4S8, TPIC_FRAAN , T; P46225, TPIC_SECCE , T;
DR    P48496, TPIC_SPIOL , T; Q57D01, TPIS1_BRUAB, T; Q8YHF5, TPIS1_BRUME, T;
DR    Q8G0F7, TPIS1_BRUSU, T; Q928I1, TPIS1_LISIN, T; Q71WW9, TPIS1_LISMF, T;
DR    Q8Y4I3, TPIS1_LISMO, T; Q2K869, TPIS1_RHIEC, T; Q98ME7, TPIS1_RHILO, T;
DR    Q92QA1, TPIS1_RHIME, T; Q2YIQ6, TPIS2_BRUA2, T; P0C119, TPIS2_BRUAB, T;
DR    Q8YCV3, TPIS2_BRUME, T; Q8FVH2, TPIS2_BRUSU, T; Q92EU4, TPIS2_LISIN, T;
DR    Q723V9, TPIS2_LISMF, T; Q8YA20, TPIS2_LISMO, T; Q2JZQ2, TPIS2_RHIEC, T;
DR    Q986N6, TPIS2_RHILO, T; Q92NH8, TPIS2_RHIME, T; P96985, TPIS3_RHIEC, T;
DR    P92119, TPIS_AEDTO , T; Q9YBR1, TPIS_AERPE , T; Q8UEY3, TPIS_AGRT5 , T;
DR    Q8YP17, TPIS_ANASP , T; P91895, TPIS_ANOME , T; O66686, TPIS_AQUAE , T;
DR    P48491, TPIS_ARATH , T; O28965, TPIS_ARCFU , T; Q750Y8, TPIS_ASHGO , T;
```

- 機能部位の説明
- パターン
- パターンを持つ配列のID
- 機能部位を持つ配列のID
- 短いパターンは偽陽性(False positive)の問題がある

POSITIVE: 機能部位に当該パターンを持つ配列の数

FALSE\_POS: 機能部位を持たないが、パターンを持つ配列の数

FALSE\_NEG: 機能部位を持つが、パターンを持たない配列の数

## PROSITE でのパターン表現

- ◆ 疑陽性が多いパターンは、SKIP-FLAG で区別できるようにしている

```
Database: PROSITE
Entry: PS00001
LinkDB: PS00001
Original site: PS00001

ID   ASN_GLYCOSYLATION; PATTERN.
AC   PS00001;
DT   APR-1990 (CREATED); APR-1990 (DATA UPDATE); APR-1990 (INFO UPDATE).
DE   N-glycosylation site.
PA   N-{P}-[ST]-{P}.
CC   /TAXO-RANGE=??E?V;
CC   /SITE=1 carbohydrate;
CC   /SKIP-FLAG=TRUE;
CC   /VERSION=1;
PR   PRU00498;
DO   PDOC00001;
//
```



## 配列プロフィール

- ◆ マルチプルアライメントの各残基位置のアミノ酸出現頻度をカウント
- ◆ Pseudocountなどを導入して正規化
- ◆ 表現方法
  - 位置特異的スコアマトリックス (PSSM: Position Specific Score Matrix または SSSM: Site Specific Score Matrix)
  - 隠れマルコフモデル
  - ブロック

## 配列プロフィール：位置特異的スコアマトリックス

### ◆ 位置 $i$ におけるアミノ酸 $j$ の出現頻度

$$Frq(i, j) = n(i, j)/N$$

- $n(i, j)$  : 位置  $i$  においてアミノ酸  $j$  が出現した個数
- $N$  : アライメントに含まれる配列の本数

### ◆ 位置 $i$ におけるアミノ酸 $j$ のスコア

$$pssm(i, j) = \ln \frac{Frq(i, j)}{P(j)}$$

- $P(j)$  : アライメントを構築している配列全体またはデータベース全体から得られるアミノ酸組成

# 配列プロファイル：位置特異的スコアマトリックス

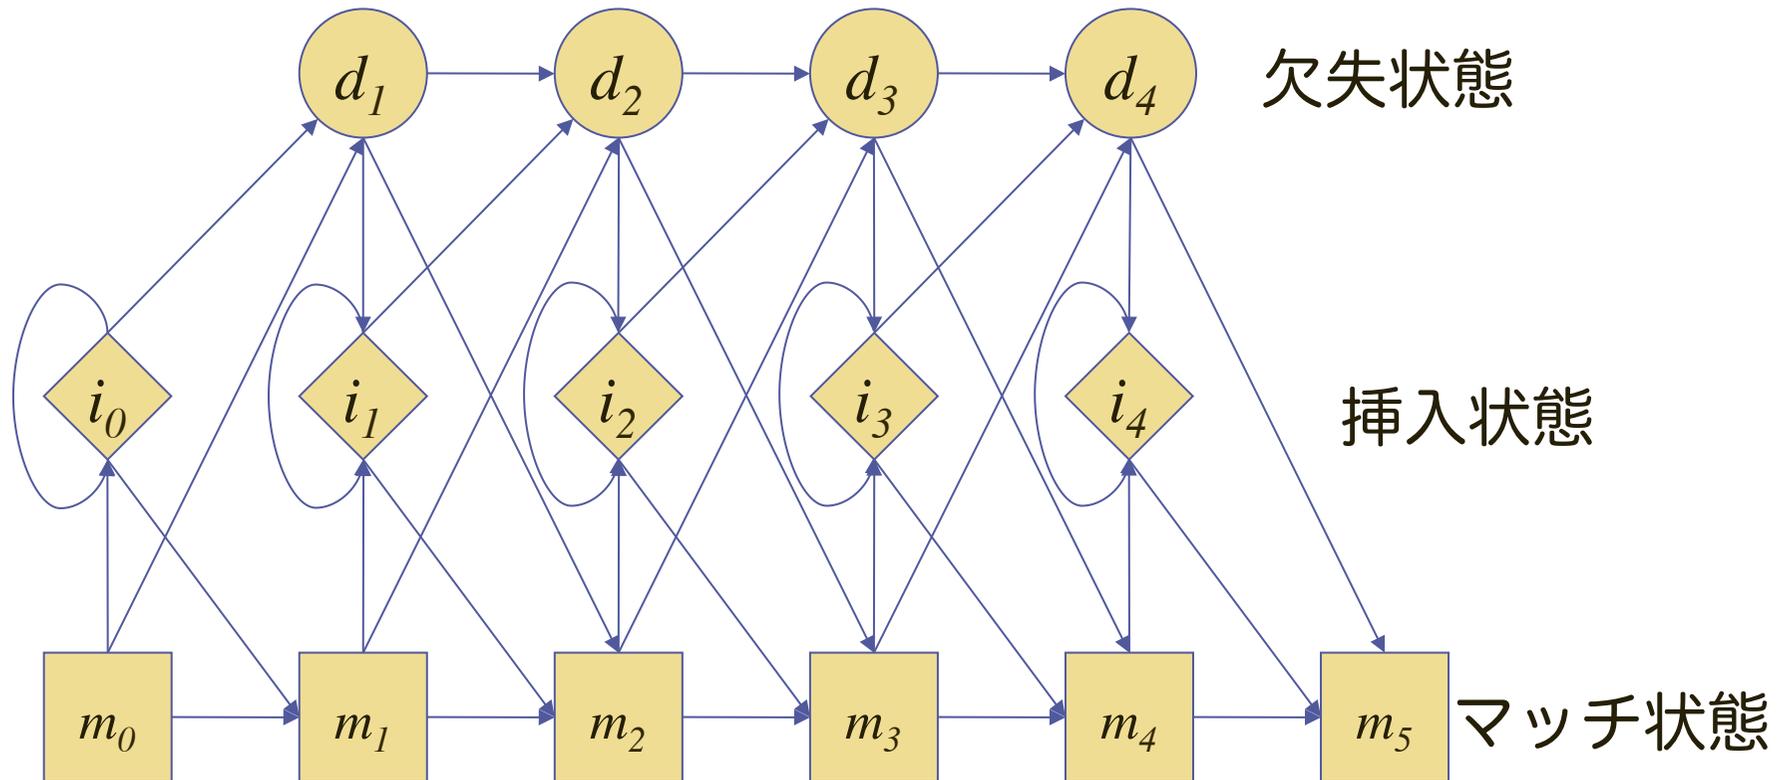
## PROSITE Profile

```
ID   ACP_DOMAIN; MATRIX.
AC   PS50075;
DT   NOV-1997 (CREATED); NOV-1997 (DATA UPDATE); JUN-2007 (INFO UPDATE).
DE   Acyl carrier protein phosphopantetheine domain profile.
MA   /GENERAL_SPEC: ALPHABET='ABCDEFGHIKLMNPQRSTVWYZ'; LENGTH=71;
MA   /DISJOINT: DEFINITION=PROTECT; N1=6; N2=66;
MA   /NORMALIZATION: MODE=1; FUNCTION=LINEAR; R1=2.3; R2=.02281121; TEXT='-LogE';
MA   /CUT_OFF: LEVEL=0; SCORE=271; N_SCORE=8.5; MODE=1; TEXT='!';
MA   /CUT_OFF: LEVEL=-1; SCORE=184; N_SCORE=6.5; MODE=1; TEXT='?';
MA   /DEFAULT: D=-20; I=-20; B1=-80; E1=-80; MI=-105; MD=-105; IM=-105; DM=-105; MM=1; M0=-1;
MA   /I: B1=0; BI=-105; BD=-105;
位置1 /M: SY='T'; M=-5,-15,-20,-17,-12,-10,-22,-18,2,-13,-1,0,-13,-6,-10,-13,-5,4,1,-23,-9,-12;
MA 2 /M: SY='E'; M=-6,-6,-22,-6,9,-13,-21,-9,-11,0,-8,-7,-7,-13,1,1,-4,-3,-8,-24,-10,4;
MA 3 /M: SY='E'; M=-5,9,-24,11,15,-24,-12,-3,-23,3,-20,-15,6,-9,5,1,4,-2,-19,-29,-16,9;
MA 4 /M: SY='E'; M=-5,2,-26,4,8,-22,-13,-7,-21,7,-17,-12,0,-13,3,7,-2,-6,-16,-22,-12,5;
MA . /M: SY='L'; M=-6,-27,-19,-30,-23,4,-30,-23,26,-25,28,17,-25,-27,-21,-20,-19,-5,23,-23,-3,-23;
MA   /M: SY='R'; M=-3,-10,-10,-11,2,-16,-19,-11,-13,-1,-8,-7,-8,-17,-1,3,-5,-6,-9,-26,-13,-1;
MA   /M: SY='E'; M=-1,3,-23,4,9,-24,-11,-7,-22,8,-19,-13,2,-11,5,6,2,-2,-17,-26,-15,7;
MA   /M: SY='I'; M=-5,-22,-20,-27,-19,-4,-29,-20,20,-19,13,10,-18,-21,-14,-17,-15,-6,14,-20,-4,-18;
MA   /M: SY='I'; M=-8,-30,-24,-33,-27,8,-29,-26,19,-24,15,9,-28,-27,-23,-21,-22,-10,17,9,4,-25;
MA   /M: SY='A'; M=11,-8,-8,-12,-5,-19,-11,-14,-14,-1,-14,-9,-6,-15,-4,-4,2,-2,-6,-25,-15,-5;
MA   /M: SY='E'; M=-5,10,-26,15,22,-28,-12,-2,-26,6,-21,-16,4,-8,10,0,2,-6,-23,-28,-16,16;
MA   /M: SY='V'; M=-5,-14,-15,-16,-6,-11,-23,-14,4,-11,0,1,-13,-19,-5,-12,-7,-5,6,-24,-8,-6;
MA   /M: SY='L'; M=-2,-24,-21,-26,-19,5,-24,-20,10,-23,22,7,-23,-24,-18,-19,-18,-7,6,-7,0,-18;
MA   /M: SY='G'; M=3,-4,-25,-5,-4,-27,24,-12,-29,-6,-25,-16,1,-12,-4,-8,5,-9,-23,-24,-22,-4;
MA   /M: SY='V'; M=-1,-12,-19,-14,-8,-11,-20,-14,4,-12,0,1,-11,-18,-10,-13,-5,-2,7,-25,-9,-10;
MA   /I: I=-4; MI=0; MD=-15; IM=0;
MA   /M: M=-2,-6,-13,-6,-5,-9,-11,-10,-2,-8,0,-2,-7,-7,-7,-8,-5,-3,-1,-18,-8,-7; D=-3;
```

SY: コンセンサス M: マトリックス

# 配列プロファイル：隠れマルコフモデル

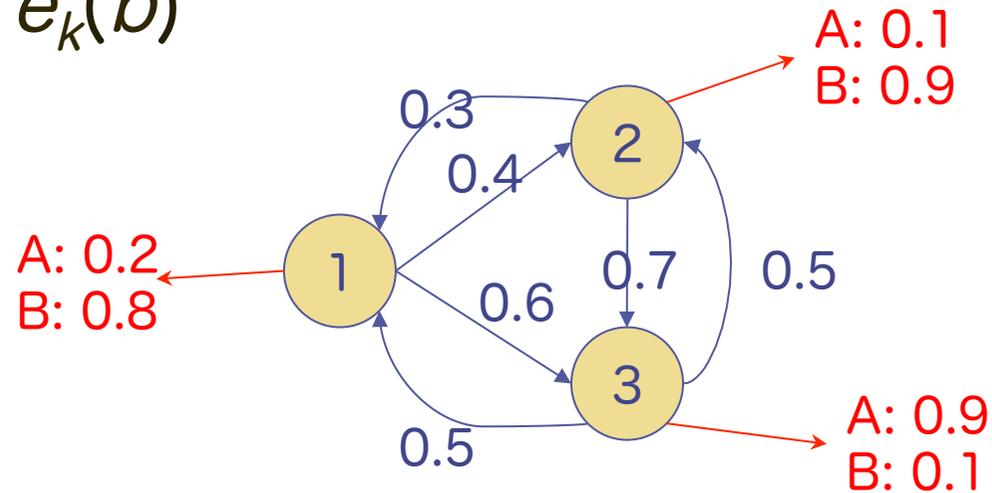
隠れマルコフモデル (HMM: Hidden Markov Model)  
1次のマルコフモデル+隠れ状態確率  
プロフィールの長さを決めてモデル化



# 配列プロフィール：隠れマルコフモデル

隠れマルコフモデル ≡ 有限オートマトン + 確率

- ◆ 出力記号集合  $\Sigma$
- ◆ 状態集合  $S = \{1, 2, \dots, n\}$
- ◆ 遷移確率 (状態  $k \rightarrow$  状態  $l$ )  $a_{kl}$
- ◆ 出力確率  $e_k(b)$



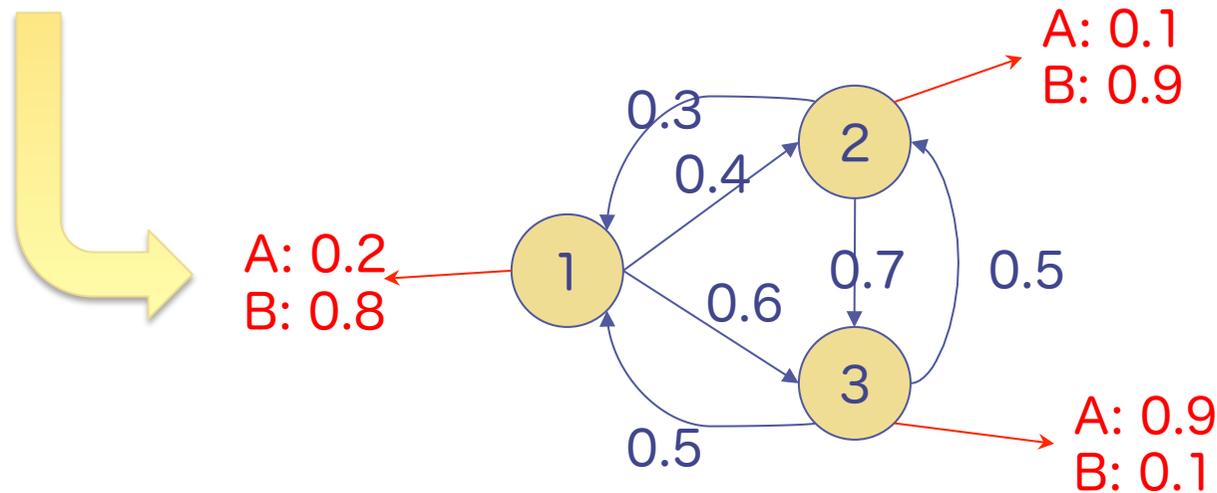
# 配列プロフィール：隠れマルコフモデル

## 隠れマルコフモデルのアルゴリズム

- ◆ Viterbi アルゴリズム
- ◆ 出力記号列から状態列を推定
- ◆ 構文解析

BABBABB

2312312

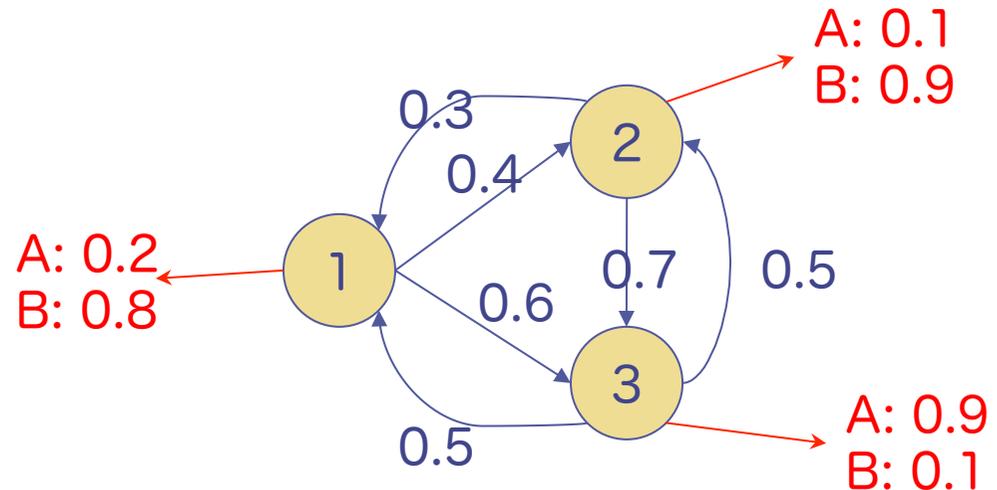
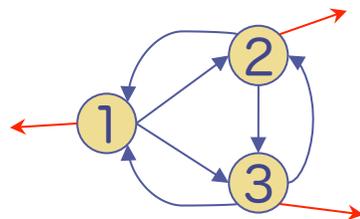


# 配列プロフィール：隠れマルコフモデル

## 隠れマルコフモデルのアルゴリズム

- ◆ Baum-Welch アルゴリズム
- ◆ EM (Expectation-Maximization) アルゴリズム
- ◆ 出力記号列からパラメータを推定
- ◆ 学習

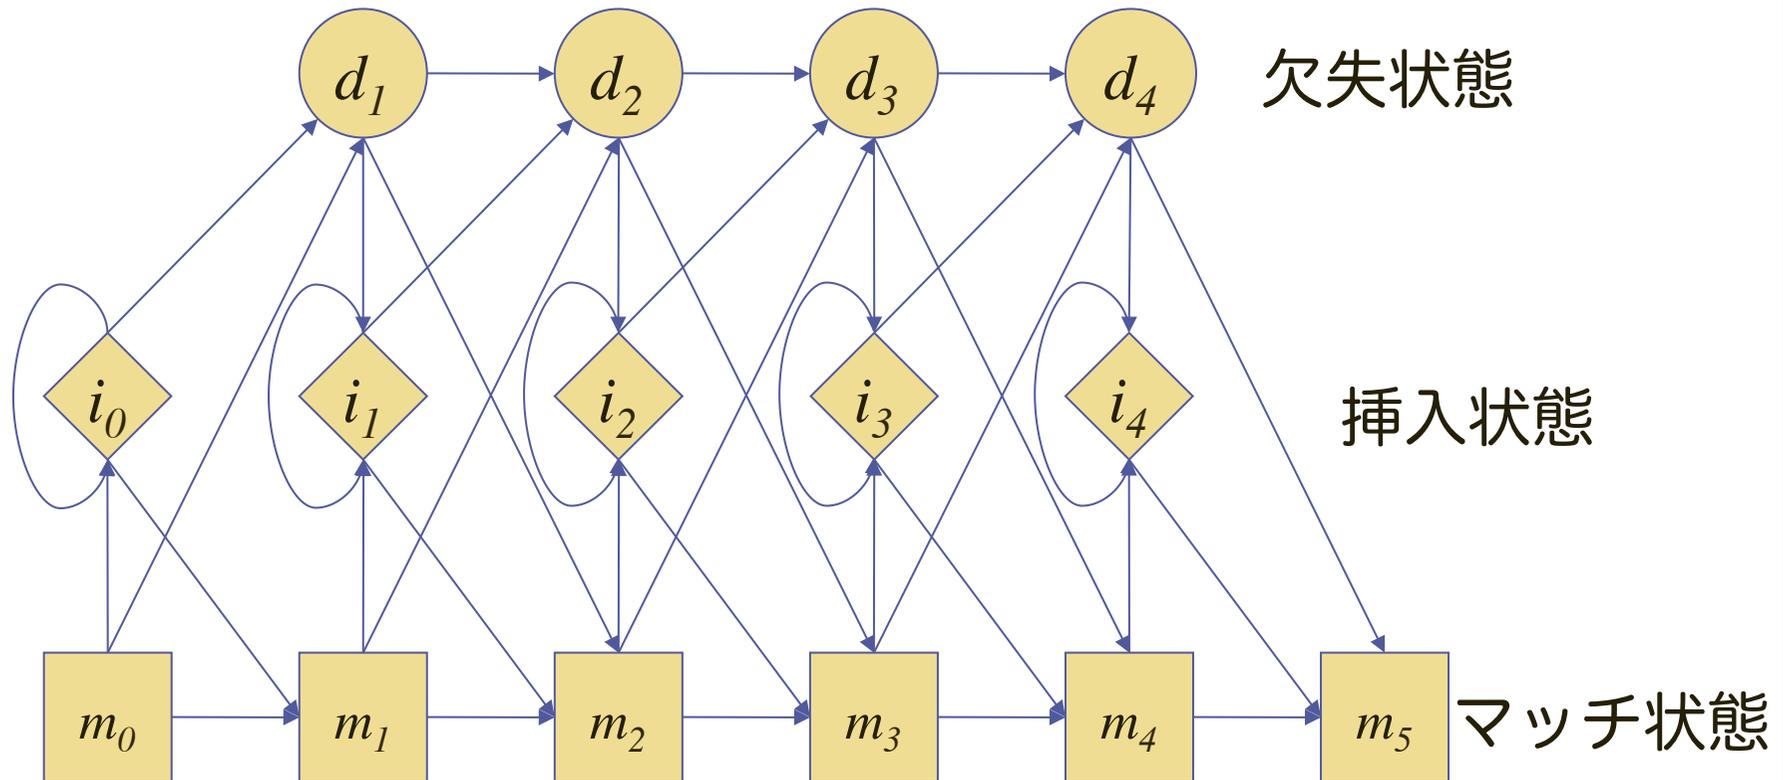
BABBABB  
BBAABBABB  
ABBABBB  
BABAABB



# 配列プロファイル：隠れマルコフモデル

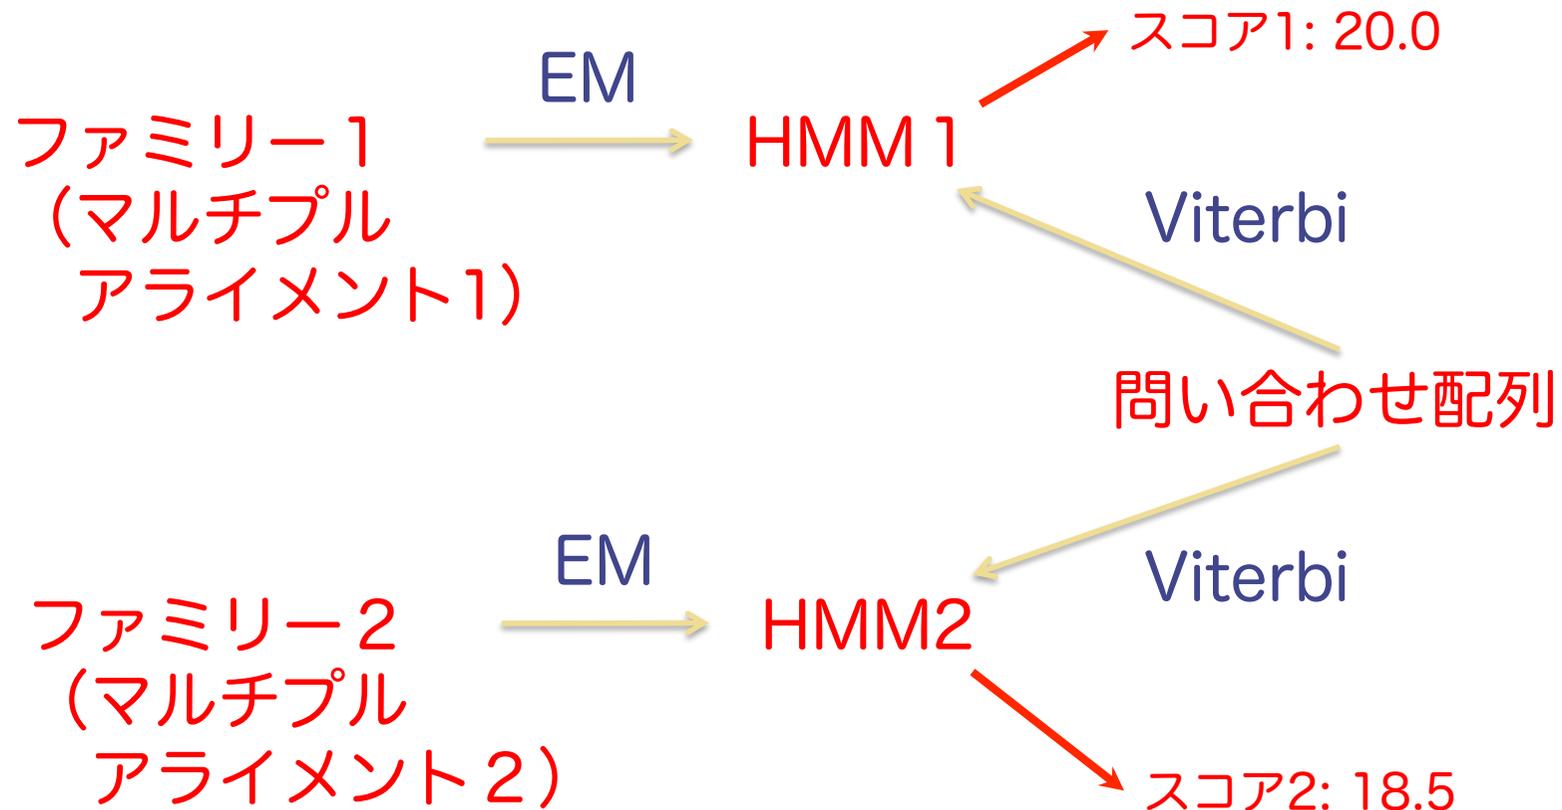
## プロフィール HMM

ファミリーごとにプロフィールの長さを決めてモデル化



# 配列プロフィール：隠れマルコフモデル

隠れマルコフモデルによるプロフィール作成とモチーフ検索



# 配列モチーフデータベース

- ◆ 配列モチーフの表現方法による分類
  - 配列パターン
    - ◆ PROSITE Pattern
  - 配列プロファイル：位置特異的スコアマトリックス
    - ◆ PROSITE Profile, NCBI-CDD
  - 配列プロファイル：隠れマルコフモデル
    - ◆ PFAM
  - その他
    - ◆ BLOCKS, PRODOM
  - 統合
    - ◆ InterPro(, NCBI-CDD)

# PFAM での配列プロフィール表現

## Family: *TIM* (PF00121)

7 architectures 3141 sequences 1 interaction 1465 species 258 structures

### Summary

### Domain organisation

### Alignments

### HMM logo

### Trees

### Curation & models

### Species

### Interactions

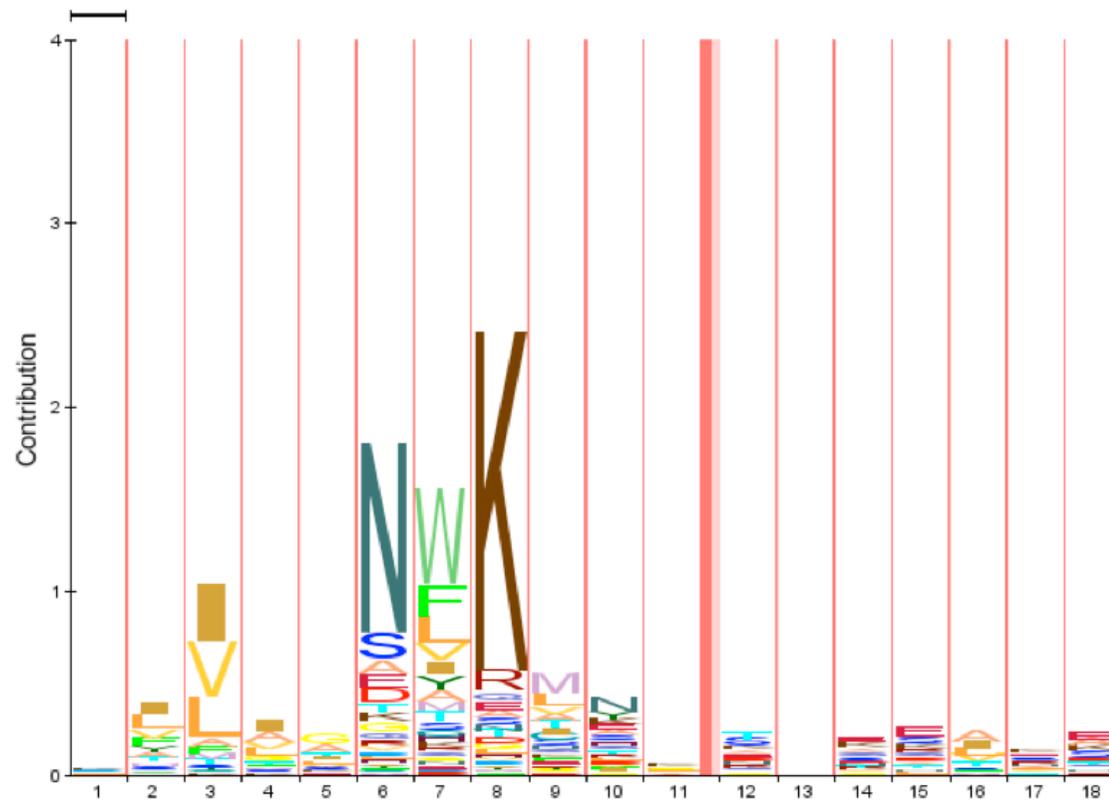
### Structures

### Jump to...



### HMM logo

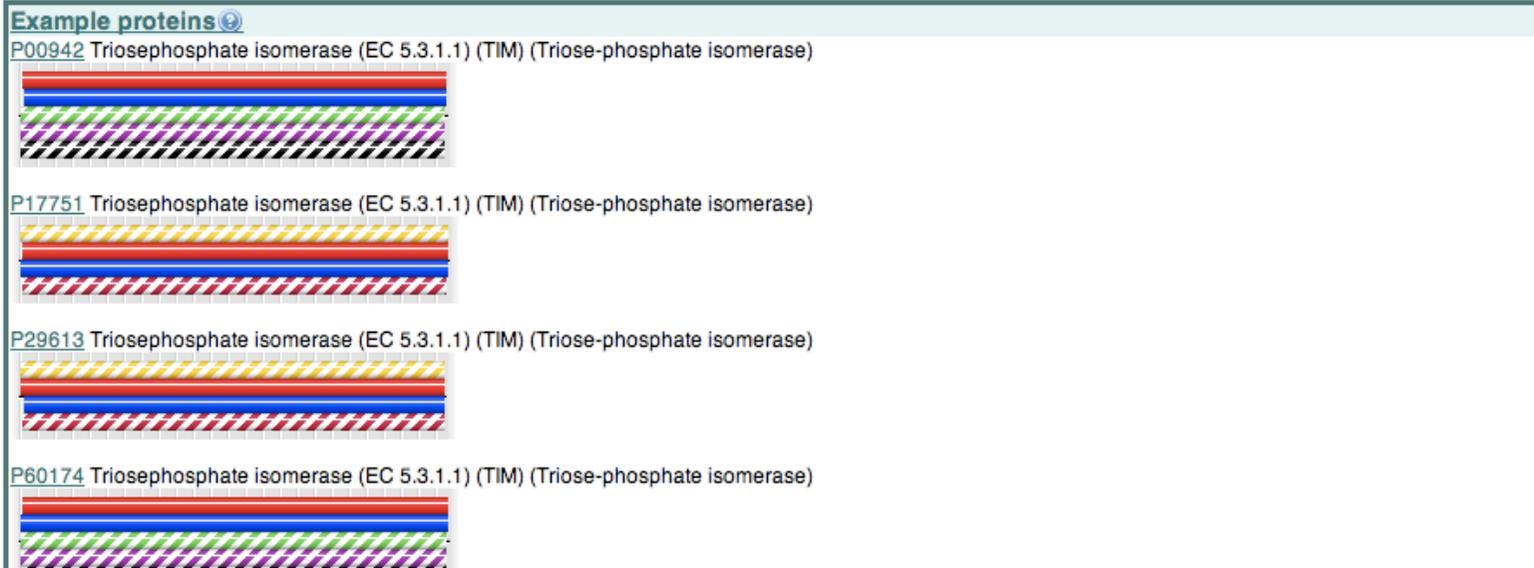
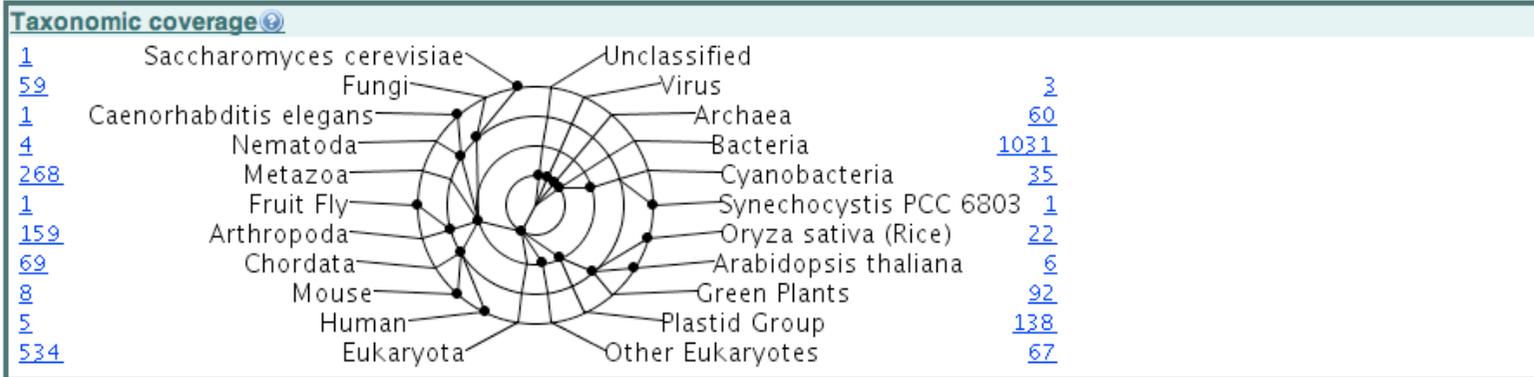
HMM logos is one way of visualising profile HMMs. Logos provide a quick overview of the properties of an HMM in a graphical form. You can see a more detailed description of HMM logos and find out how you can interpret them [here](#). [More...](#)



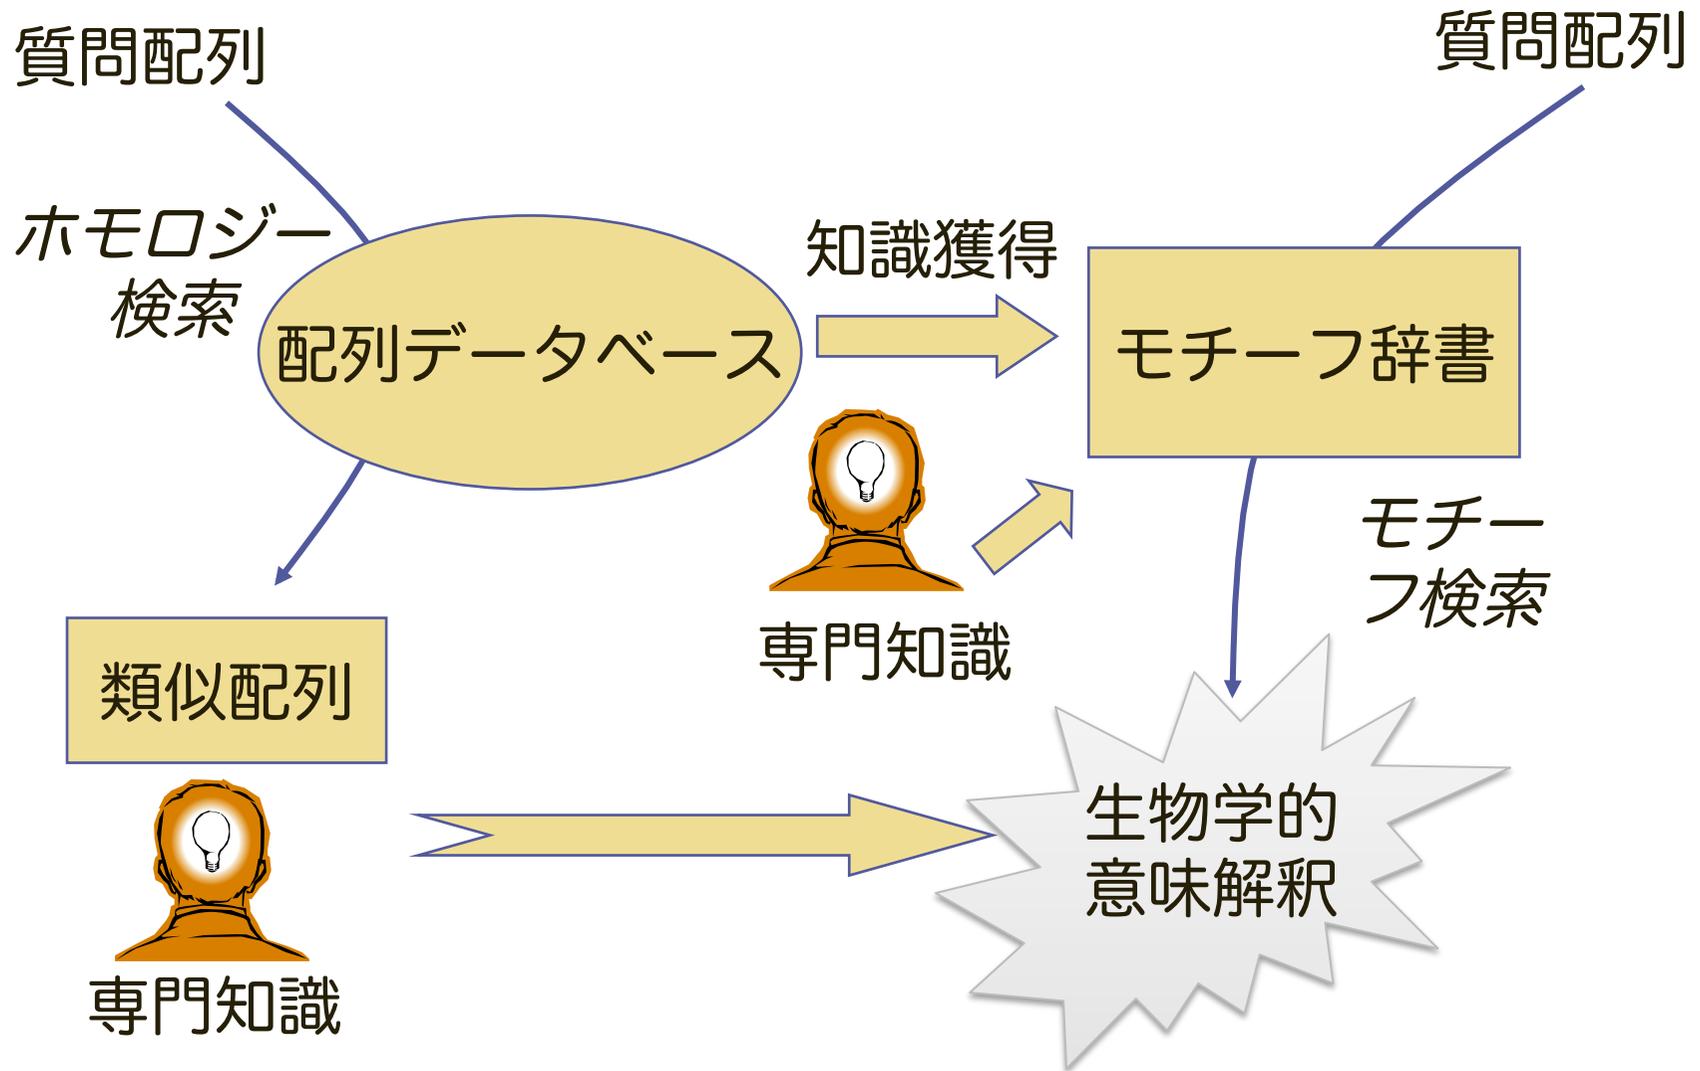
# InterPro による配列モチーフデータベースの統合

InterPro: IPR000652 Triosephosphate isomerase				
<b>Matches</b>	<b>Overview:</b> <a href="#">sorted by AC</a> , <a href="#">sorted by name</a> , <a href="#">of known structure</a> , <a href="#">proteins with splice variants</a> <b>Detailed:</b> <a href="#">sorted by AC</a> , <a href="#">sorted by name</a> , <a href="#">of known structure</a> <a href="#">proteins with splice variants</a> <b>Table:</b> <a href="#">For all matching proteins</a> , <a href="#">of known structure</a> <a href="#">Architectures</a>			
<b>Accession</b>	IPR000652 Triophos_ismrse Matches: 1629 proteins			
<b>Type</b>	Family			
<b>Signatures</b>	Database	ID	Name	Proteins
	<a href="#">ProDom</a>	<a href="#">PD001005</a>	Triophos_ismrse	1442
	<a href="#">Pfam</a>	<a href="#">PF00121</a>	TIM	1282
	<a href="#">PROSITE pattern</a>	<a href="#">PS00171</a>	TIM	960
	<a href="#">PANTHER</a>	<a href="#">PTHR21139</a>	Triophos_ismrse	1241
	<a href="#">SuperFamily</a>	<a href="#">SSF51351</a>	Triophos_ismrse	1452
	<a href="#">TIGRFAMs</a>	<a href="#">TIGR00419</a>	tim	909
<b>InterPro Relationships</b>				
<b>Contains</b>	<a href="#">IPR013785</a> Aldolase-type TIM barrel			
<b>GO Term annotation</b>				
<b>Process</b>	<a href="#">GO:0008152</a> metabolic process			
<b>Function</b>	<a href="#">GO:0004807</a> triose-phosphate isomerase activity			
<b>InterPro annotation</b>				
<b>Abstract</b>	<p>Triosephosphate isomerase (<a href="#">EC:5.3.1.1</a>) (TIM) [1] is the glycolytic enzyme that catalyzes the reversible interconversion of glyceraldehyde 3-phosphate and dihydroxyacetone phosphate. TIM plays an important role in several metabolic pathways and is essential for efficient energy production. It is a dimer of identical subunits, each of which is made up of about 250 amino-acid residues. A glutamic acid residue is involved in the catalytic mechanism [2]. The sequence around the active site residue is perfectly conserved in all known TIM's. Deficiencies in TIM are associated with haemolytic anaemia coupled with a progressive, severe neurological disorder [3].</p>			
<b>Structural links</b>	CATH: <a href="#">3.20.20.70</a> SCOP: <a href="#">c.1.1.1</a> , <a href="#">c.1.31.1</a> <a href="#">PDB - click here</a>			
<b>Database links</b>	PANDIT: <a href="#">PF00121</a> PROSITE doc: <a href="#">PDOC00155</a> Blocks: <a href="#">IPB000652</a> MSDsite: <a href="#">PS00171</a> Pfam Clan: <a href="#">CL0036.15</a>			

# InterPro による配列モチーフデータベースの統合



# ホモロジー検索とモチーフ検索



## 関連ウェブサイト

### ◆ モチーフデータベース

#### ■ キーワード検索

- ◆ [http://www.genome.jp/dbget-bin/www\\_bfind?motifdic](http://www.genome.jp/dbget-bin/www_bfind?motifdic)
- ◆ <http://www.ebi.ac.uk/interpro/>

#### ■ 塩基配列

- ◆ 転写因子結合サイトなど：EPD, TransFac, JASPER

### ◆ モチーフ検索

#### ■ <http://www.genome.jp/tools/motif/>

- ◆ 質問配列が既知のモチーフを持つか
- ◆ 質問モチーフを持つ配列を配列データベースから探す
- ◆ マルチプルアライメントからプロファイルを作る

#### ■ PSI-BLAST: Position Specific Iterated BLAST

- ◆ <http://www.ncbi.nlm.nih.gov/BLAST/>