

# 機能アノテーションパイプライン(仮)

理化学研究所

発生・再生科学総合研究センター(CDB)

機能ゲノミクスサブユニット

粕川雄也

# 発表の概要

- 機能アノテーションってなに？
- 機能アノテーションはどうやってつけるの？
- パイプライン化 & ハイスループット化するには？

# 発表の概要

- 機能アノテーションってなに？
- 機能アノテーションはどうやってつけるの？
- パイプライン化 & ハイスループット化するには？

# 機能アノテーションとは？

- DNA: DNA配列, ゲノム中の領域
- RNA: 転写配列, mRNA配列, non-coding RNA配列
- タンパク質: アミノ酸配列
- DNA Chip/Microarray上の probe
  - などなどの種々の「配列情報」

に対する「機能についての情報ならばどんなものでも」。例えば

- 遺伝子名
- 機能記述・定義
- Gene Ontology
- 機能している時間・場所  
などなどなど

# 機能アノテーションがなぜ必要なの？

- 配列を決めること

- 簡単（ルーチン化されている）
- 安い
- たくさん手に入れられる

- 機能を決めること

- 難しい（ルーチン化されていない）
- 高い
- 少しずつしか手に入らない



研究の  
流れ

だから、配列が先に決められる  
→配列を手がかりに機能情報の収集

# 発表の概要

- 機能アノテーションってなに？
- 機能アノテーションはどうやってつけるの？
- パイプライン化 & ハイスループット化するには？

# 機能アノテーションをつけよう

- どうするか？

- 機能アノテーションをつけられる人間とか研究室を探し出してきておしつける
  - 一番楽な方法だが，そう簡単には見つからないし，後で揉めるかもしれない
- 適当に面白そうな機能をつけてしまう
  - あとで諸々の問題になるのでやめたほうがいい
- 他のところから機能情報を「いただく」。
  - 最も正しい方法
  - 配列情報をキーに公共データベースから機能情報を抽出

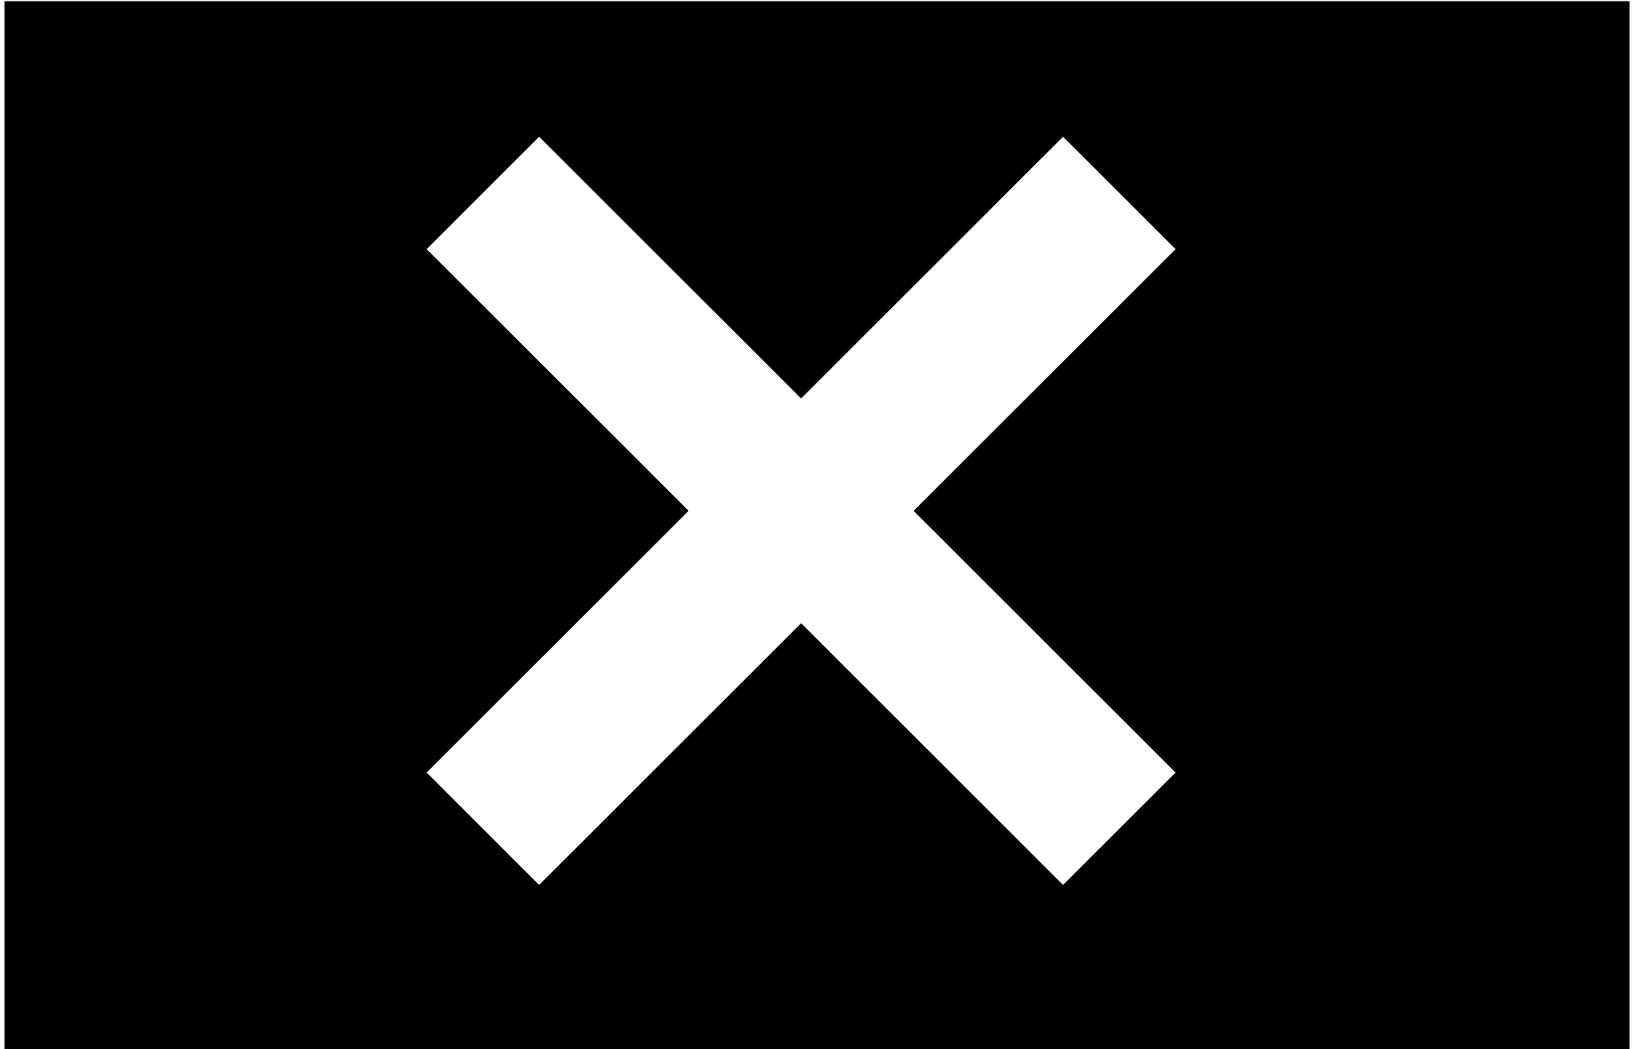
# 今回の注意

- 今回は,
  - マウスのmRNA配列に対して,
  - 遺伝子記述(遺伝子定義)を与えることを考える。

```
>gi|60551214|gb|BC091645.1|
GCCGAAACGGCAAGCGGATGGAGGGCGCTCGAACGGCCAGGTGTCGTGATTAAATTAGTCAGCCCTCAGA
GACAGGCGTCCTACCTCCTTTATCCAGACCTCAAAGCCCCGTTGTGCACCCGTGGTGGCTTCTTCACCT
TCCCTGTTTCGTCTCCTCCACTGTATGGCCCAGACATGAGTGGTCCCCTAGAAGGGGCCGATGGGGGAGGAG
ACCCAGGCCCGGAGAACCTTTTTGTCTGAGGAGTCCCATCCCCTGGGGCCCCGCAGCACCGGCCTTG
TCCAGGCCCCAGCCTGGCTGATGACACTGATGCAAACAGCAATGGCTCAAGTGGCAATGAGTCCAACGGA
CCCGAGTCCAGGGGCGCATCTCAGCGGAGTTCTCATAGTTCCTCTTCTGGCAATGGCAAGGACTCAGCTC
TGCTGGAGACCACTGAGAGCAGCAAGAGTACAACTCACAGAGCCCATCCCCACCCAGCAGCTCCATTGC
CTACAGCCTCCTGAGTGCGAGCTCAGAGCAGGACAACCCATCTACCAGTGGCTGCAGCAGTGAACAGTCA
GCTCGAGCCAGGACCCAGAAAGAACTCATGACTGCACTTCGGGAGCTCAAACCTTCGACTGCCACCAGAGC
GTCGGGGCAAGGGCCGCTCTGGGACCTTGGCCACACTGCAGTACGCTCTGGCCTGTGTCAAGCAGGTTCA
GGCTAACCCAGGAATATTACCAGCAGTGGAGTCTGGAGGAGGGTGAGCCTTGTGCCATGGACATGTCTACT
TACACCCTGGAGGAATTGGAGCATATCACATCCGAATACACACTTCGAAACCAGGACACCTTCTCTGTGG
```

問題 機能情報が与えられていない配列があったときに、まず最初に行うことは、BLASTやFASTAなどの配列類似性検索である。○か×か？

正解



正解 ×

まず最初に、その配列自体の(機能)情報がないかどうかを公共データベースから探す

配列が公開されていたら、たいてい親切な誰かが機能情報をつけてくれていることが多い

# 一般的な機能アノテーションの流れ

1. 公共データベースから、その配列自身の機能情報を直接検索
2. それがだめなら、同じ配列を配列類似性検索
3. それもだめなら、アミノ酸配列の似ているタンパク質を配列類似性検索
4. それもだめなら、タンパク質ファミリー特異的なタンパク質ドメインをドメイン探索
5. それもだめなら、ncRNAか機能未知なのでしょう

# 1. データベースを直接検索

- 公開配列であれば, IDがついている。
- そのIDをキーにデータベースを検索し, そのIDに付与されている機能情報を「いただく」
- 使えるデータベースには, たとえば,
  - Mouseの配列なら
    - MGI (Mouse Genome Informatics) <http://www.informatics.jax.org/>  
<ftp://ftp.informatics.jax.org/pub/>
  - Humanとか代表的な生物の配列なら
    - Entrez Gene <http://www.ncbi.nlm.gov/entrez/query.fcgi?db=gene>  
<ftp://ftp.ncbi.nih.gov/gene/>
  - タンパク質なら
    - UniProt (<http://www.uniprot.org/>)
  - Affymetrix GeneChipのprobeset なら
    - <http://www.affymetrix.com/analysis/index.affx> (要登録)

# 1. データベースを直接検索

The screenshot shows a Microsoft Internet Explorer browser window with the title "MGI\_3.3: Search Results - Microsoft Internet Explorer". The address bar displays the URL: <http://www.informatics.jax.org/javaw12/servlet/WIFetch?page=searchTool&query=BC091645&selecte>. The page content includes the MGI logo and navigation links. A search box on the left contains the query "BC091645" and a "Go" button. Below the search box is a list of sections to search in, with "Gene symbols/names" selected. The main search results area is titled "Search Results" and shows the search for "BC091645" in "Accession IDs". A table lists three results, with the second row highlighted by a red circle. The description for this row is also circled in red.

AccID	Database	MGI Links	Type	Description
BC091645	<a href="#">GenBank</a>   <a href="#">EMBL</a>   <a href="#">DDBJ</a>	<a href="#">MGI Sequence Detail</a>	RNA	Mus musculus period homolog 1 (Drosophila), mRNA (cDNA clone MGC:102121 IMAGE:30355259), complete cds
BC091645	<a href="#">GenBank</a>   <a href="#">EMBL</a>   <a href="#">DDBJ</a>	<a href="#">MGI Marker Detail</a>	Gene	Per1, period homolog 1 (Drosophila), Chr 11
BC091645	<a href="#">GenBank</a>   <a href="#">EMBL</a>   <a href="#">DDBJ</a>	<a href="#">MGI Probe/Clone Detail</a>	cDNA	IMAGE clone 30355259

# 1. データベースを直接検索

- 流れ

- 基本的にデータベースごとに個別対応
- 1個ずつ手動でがんばる場合
  - WWWで検索→結果を手で抽出
- まとめて処理する場合
  - データダウンロードサイトからファイルを取得→データ抽出→データ結合
  - もしくはMySQL等で自分用のデータベースを構築して、処理

# 1. データベースを直接検索

[ftp://ftp.informatics.jax.org/pub/reports/MRK\\_Sequence.rpt](ftp://ftp.informatics.jax.org/pub/reports/MRK_Sequence.rpt)

MGI:1098283	Per1	O	Gene	<u>period homolog 1 (Drosophila)</u>					
syntenic	11		AB002108	AB030818	AF022992	AK081813	AK148202		
AK154900	AK172958	AK182563	AL645527	BC039768	BC091645			7373	
NM_011065									
MGI:1195265	Per2	O	Gene	period homolog 2 (Drosophila)					
syntenic	1		AA272850	AF035830	AF036893	AK044658	AK122253		
AK159847	AK165556	BC055933	218141	NM_011066					

## 2. 同じ配列を探す

- 「同じ配列⇔同じ機能」
- なので,
  - 同じ配列が公共データベースに存在し, その配列に機能情報があれば, その配列の機能情報を「いただく」
  - 「いただいた」機能情報は
    - そのまま使う
    - いただいた元の情報(場所・データベース名・ID)はつける

## 2. 同じ配列を探す

The image shows two overlapping browser windows from NCBI. The background window is the BLAST search page, and the foreground window shows the results for a specific query.

**Background Window (BLAST Search Page):**

- Address: [http://www.ncbi.nih.gov/BLAST/Blast.cgi?CMD=Web&LAYOUT=TwoWindows&AUTO\\_FORMAT=Semiauto&ALIGNM](http://www.ncbi.nih.gov/BLAST/Blast.cgi?CMD=Web&LAYOUT=TwoWindows&AUTO_FORMAT=Semiauto&ALIGNM)
- Search query: `>gi|60551214|gb|BC091645.1|GCCGAAACGGCAAGCGGATGGAGGGCGCTCGAACGGCCAGGTGTCGTGATTAATTAAGCCCTCAGA GACAGGCGTCTACCTCCTTTATCCAGACCTCAAAAAGCCCGTTGTGCACCCGTTGTTCTTCACT`
- Database: `refseq_ma`
- Buttons: **BLAST!**, **Reset query**, **Reset all**

**Foreground Window (BLAST Results):**

- Address: <http://www.ncbi.nih.gov/BLAST/Blast.cgi>
- Buttons: **Get selected sequences**, **Select all**, **Deselect all**
- Hit: `>gi|31559795|ref|NM_011065.2|U E G Mus musculus period homolog 1 (Drosophila) (Per1), mRNA`  
Length=4701
- Statistics: Score = 4742 bits (2392), Expect = 0.0, Identities = 2413/2413 (100%), Gaps = 0/2413 (0%), Strand=Plus/Plus
- Sequence Alignment:

Query	Sequence	Position
1	GCCGAAACGGCAAGCGGATGGAGGGCGCTCGAACGGCCAGGTGTCGTGATTAATTAGTC	60
Sbjct		53
61	AGCCCTCAGAGACAGGCGTCTACCTCCTTTATCCAGACCTCAAAAAGCCCGTTGTGCAC	120
Sbjct		113
121	CCGTGGTGGCTTCTTCACTTCCCTGTTTCGTCTCCACTGTATGGCCAGACATGAGTG	180
Sbjct		173
181	GTCCTTAGAAGGGCCGATGGGGAGGAGACCCAGGCCCGGAGAACCTTTTGTCCCTG	240
Sbjct		233
241	GAGGAGTCCCATCCCCTGGGCCCCGAGCACCAGCCCTTGTCCAGGCCACGCTGGCTG	300
Sbjct		293
301	ATGACTAGTGCAACAGCAATGGCTCAAGTGGCAATGAGTCCAACGGACCCGAGTCCA	360

## 2. 同じ配列を探す

- 探す相手

- 「1.データベースを直接検索」のデータベースの配列を使う

- 探し方

- 配列類似性検索プログラムで, DNA同士もしくはアミノ酸配列同士の検索を行う

- プログラム

- BLASTN(塩基同士)    BLASTP(アミノ酸同士)
- FASTA(どちらでも)    など
- プログラムはいくつかあるが「同じ配列」を探すときは基本的に大差なし
- 許されるギャップの長さがかなり異なる(要注意:alternative splicing)

### 3. 似た配列を探す

- 「似た配列⇔似た機能」
- なので,
  - 似た配列が公共データベースに存在し, その配列に機能情報があれば, その配列の機能情報を「いただく」
  - 「いただいた」機能情報は
    - 「～～に似ている」という情報にする
    - いただいた元の情報はもちろんつける

# 3. 似た配列を探す

NCBI Blast - Microsoft Internet Explorer

ファイル(F) 編集(E) 表示(V) お気に入り(A) ツール(I) ヘルプ(H)

戻る 進む 検索 お気に入り

アドレス(D) http://www.ncbi.nih.gov/BLAST/Blast.cgi?CMD=Web&LAYOUT=TwoWindows&AUTO\_FORMAT=Semiauto&ALIGNM

Search

>gi|60551214|gb|BC091645.1|  
GCCGAAAACGGCAAGCGGATGGAGGGCGCTCGAACGGCCAGGTGTCGTGATTAAATTAGTC  
AGCCCTCAGA  
GACAGGGCGTCTACCTCCTTTATCCAGACCTCAAAAAGCCCGCTTGTGCACCCGTTGGG  
TTCTTCACCT

Choose a translation TRANSLATED query - PROTEIN database [blastx]

Set subsequence From: To:

Choose database nr

Genetic codes Standard (1)

Now: **BLAST!** or Reset query Reset all

Options for advanced blasting

Limit by entrez or select from All organisms

RID=1128949305-22535-134706069412.BLASTQ1, gi|60551214|gb|BC091645.1 - Microsoft Internet Explorer

ファイル(F) 編集(E) 表示(V) お気に入り(A) ツール(I) ヘルプ(H)

戻る 進む 検索 お気に入り

アドレス(D) http://www.ncbi.nih.gov/BLAST/Blast.cgi#6174900

> [gi|18093872|sp|O15534|PER1\\_HUMAN](#) **6** Period circadian protein 1 (Circadian pacemaker protein Rigi1) (hPER)  
Length=1290

Score = 1183 bits (3008), Expect = 0.0  
Identities = 753/793 (94%), Positives = 762/793 (96%), Gaps = 0/793 (0%)  
Frame = +3

Query 174 MSGPLEGADGGGDP RPGE PFC PGGVPS PGAPQHRC PGP SLADDDAXXXXXXXXXXXXX 353  
Sbjct 1 MSGPLEGADGGGDP RPGE FCPGGVPS PG PQRPC PGP SLADDDANSGNGSGNESNG 60

Query 354 XXQDNPS 533  
Sbjct 61 ESRGASORSSHSSSSGNGKDSALLETTSSKSTNSQSPSPSSSIAYSLLSASSEQDNPS 120

Query 534 TSGCSSEQSARARTQKELMTXXXXXXXXXXXXXGKGRSGTLATLQYALACYKQVQANQE 713  
Sbjct 121 TSGCSSEQSARARTQKELMTALRELKLRPPERRGKGRSGTLATLQYALACYKQVQANQE 180

Query 714 YYQWWSLEEGEPCAMDSTYTLLELEHITSEYTLRNDQTFVAVSFLTGRIVYIYISEQAGY 893  
Sbjct 181 YYQWWSLEEGEPCAMDSTYTLLELEHITSEYTLRNDQTFVAVSFLTGRIVYIYISEQAAY 240

Query 894 LLRCKRDVFRGRFSELLAPQDVGVFYGSTTPSRLPTWGTGTSAGSGLKDFDTEKSYFCR 1073  
Sbjct 241 LLRCKRDVFRGRFSELLAPQDVGVFYGSTAPSRLPTWGTGASAGSGLRDFDTEKSYFCR 300

Query 1074 IRGGPDRDPGRPYQPFRLTPYVTKIRVSDGAPAPCCLLIAERIHSGYEAPRIPPKRIF 1253  
Sbjct 301 IRGGPDRDPGRPYQPFRLTPYVTKIRVSDGAPAPCCLLIAERIHSGYEAPRIPPKRIF 360

### 3. 似た配列を探す

- 探す相手
  - UniProt配列を使うのがおすすめ
- 探し方
  - 配列類似性検索プログラムで、アミノ酸配列への検索を行う。
    - 翻訳されるアミノ酸配列が分かる
      - BLASTP, FASTA を使う
    - DNA配列だけしかわからない
      - BLASTX, FASTX/FASTYを使う
  - どのプログラムを使うかで、計算時間、ギャップの入れ方が違うのでよく検討して選択する
    - 例えば, fastyはどこにでもギャップが入るが, 非常に遅い

## 4. タンパク質ファミリーを探す

- 「タンパク質ドメインがある  
⇔タンパク質ファミリーに属する  
⇔そのファミリー共通の機能をもつ」

タンパク質ドメインの例: NAD(P)H dehydrogenase family

タンパク質

ACPD\_BACSU (O35022) Putative acyl carrier protein phosphodiesterase (EC 3.1.4.14) (ACPphosphodiesterase).

Q97DQ1 ACYL CARRIER PROTEIN PHOSPHODIESTERASE

Q9K5P5 NAD(P)H DEHYDROGENASE (QUINONE)



### マルチプルアライメント

```
YA05_SCHPO/1-192 MKILLINGAQEFA...HSQGKFNKTLHNVAKDT..LIQLGHTVQETVVDEGYD.....ENT.EVEKIL
Q9PMC4/2-192     KNILLLNKAKEFG...NSKGQLNLTLHNHALEI..LKTLDGYEVDQTHIDQGYD.....PKE.EIQKFI
O25347/2-193     KKVLIINGAKAFG...SSGGKLNELTLDHAKKT..LESGLLEVDTTIVDKGYE.....HAQ.EVEKVF
MDAB_HAEIN/1-192 MNILLLDGGKAFG...HSHGELNHTLHKKAKEV..LTALGHNVKETVIDAGYD.....VEA.EIEKFL
Q9I0Q6/2-193     KNILLLNKGKRFA...HSDGRLNQTTLHETALAH..LDRRGFDLRQTFIDGGYD.....IPT.EVDKFL
MDAB_ECOLI/2-193 SNILIINGAKKFA...HSNGQLNDTLTEVADGT..LRDLGHDRVIVRADSDYD.....VKA.EVQNFL
```

## 4. タンパク質ファミリーを探す

- なので,
  - 似た既知タンパク質ドメインがあれば, そのタンパク質ドメイン(ファミリー)の機能情報を「いただく」
  - 「いただいた」機能情報は
    - 「～(ドメイン名)～というドメインを持つ」という情報にする
    - いただいた元の情報はもちろん記録

# 4. タンパク質ファミリーを探す

Protein matches - Microsoft Internet Explorer

ファイル(F) 編集(E) 表示(Y) お気に入り(A) ツール(T) ヘルプ(H)

戻る 検索 お気に入り

アドレス(D) <http://www.ebi.ac.uk/interpro/ISpy?mode=single&ac=035973> 移動 リンク

## InterPro Protein matches

Click here for help!

Select: ?	Protein accession:	035973
	OR: Entry accession:	
Refine: ?	Splice variants:	<input type="checkbox"/>
	Proteins with known structure:	<input type="checkbox"/>
Display: ?		
Sort: ?		

View

Protein ?	Match line ?
	<ul style="list-style-type: none"><li>Table of Matches</li><li>GO annotation</li><li>View protein UniProt information</li></ul>
 UniProt: 035973 Scale:10aa PER1_MOUSE GO!	 InterPro Signatures ? IPR000014 PS50112 IPR000700 PS50113

一般 CAPS KANA

## 4. タンパク質ファミリーを探す

- 探す相手
  - [Pfam](http://pfam.wustl.edu/) (http://pfam.wustl.edu/)
  - [InterPro](http://www.ebi.ac.uk/interpro/) (http://www.ebi.ac.uk/interpro/)
- 方針
  - DNA配列だけしかわからない
    - [Wise2パッケージのestwisedb](http://www.ebi.ac.uk/Wise2/) (http://www.ebi.ac.uk/Wise2/) を使って, 「Pfamドメイン」を探す
  - 翻訳されるアミノ酸配列が分かる
    - [InterProScan](http://www.ebi.ac.uk/InterProScan/) (http://www.ebi.ac.uk/InterProScan/) を使って, 「InterProドメイン」を探す
- 計算時間がかかるので注意
  - かかる時間に対して, それほど情報は増えない
  - humanやmouseなどゲノム規模でタンパク質情報が収集されているのであれば, とばしてもよい

## 5. ncRNA

- 今のところ

- 既知ncRNA配列に対する配列類似性検索

- RNADB (<http://research.imb.uq.edu.au/rnadb/>) などを使う

- RNAファミリー探索

- Rfam (<http://www.sanger.ac.uk/Software/Rfam/>)
- infernal (<http://www.genetics.wustl.edu/eddy/infernal/>)

がある。今後に期待

## 5. 機能未知

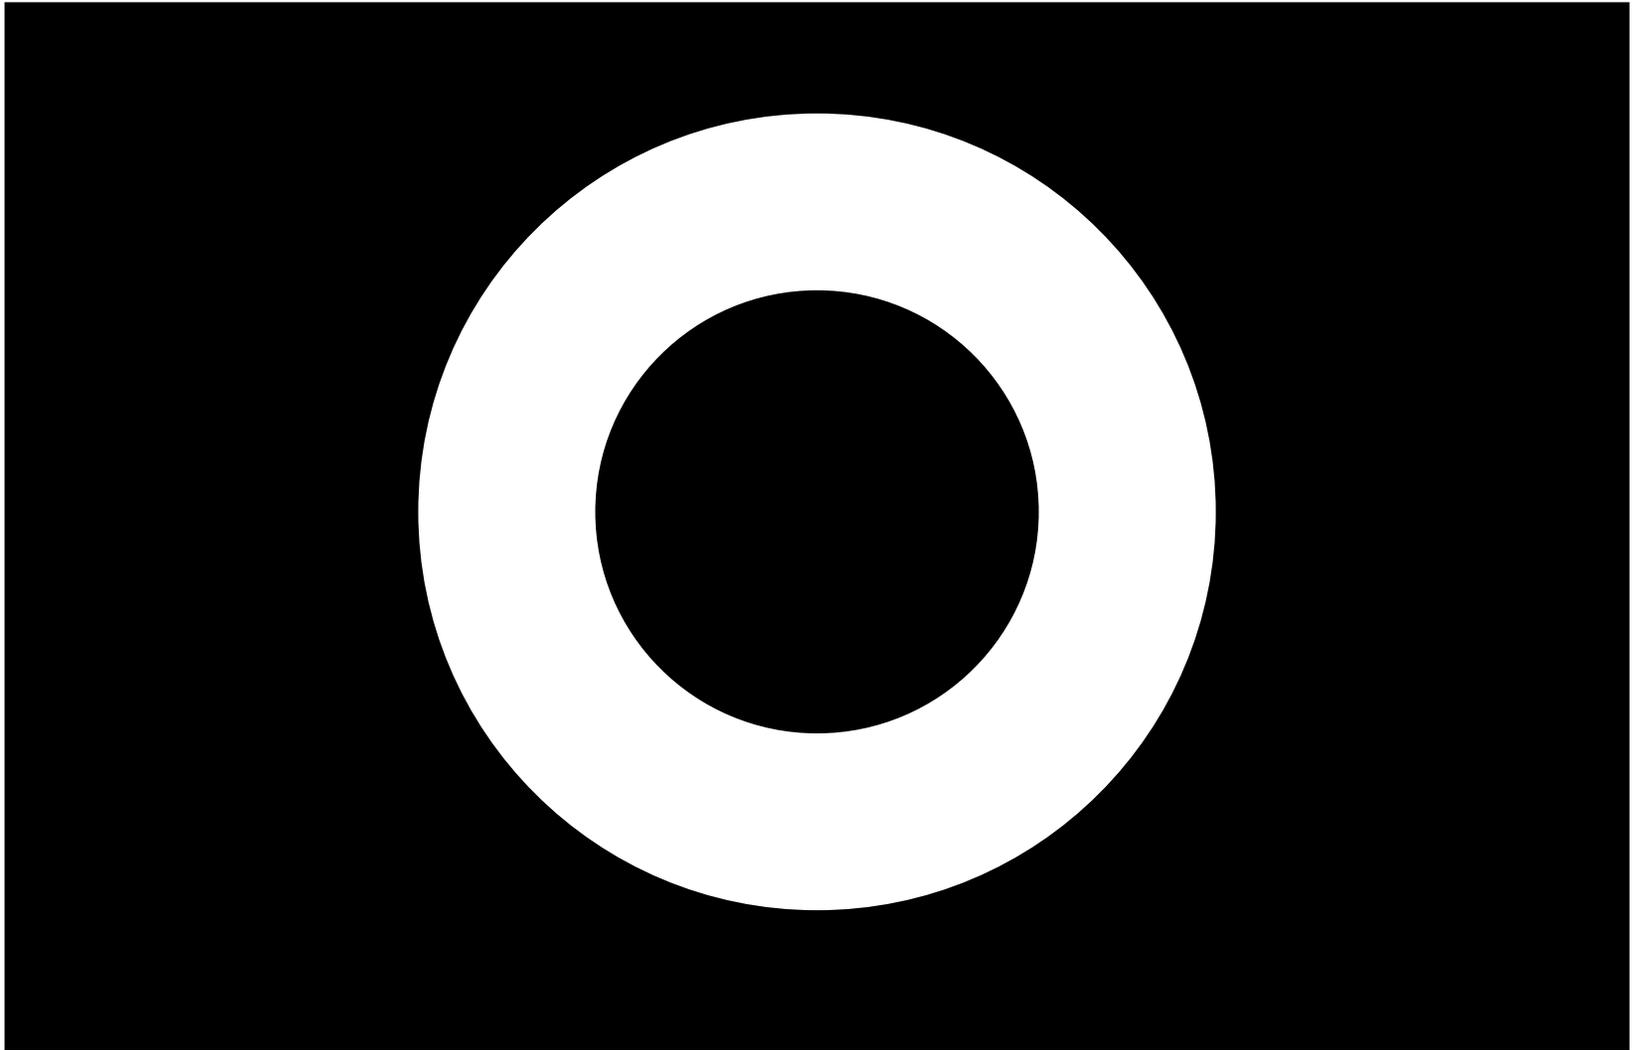
- 分からなかった場合は「分からなかった」という情報をつけておく
    - 「宝の入ったゴミの山」
  - ただし、「宝」と「ゴミ」を区別できるように,
    - きれいなタンパク質に翻訳できそうか
      - タンパク質コード領域予測
    - ESTとなら一致するか？
      - dbESTなどに対する配列類似性検索
- も情報としてつけておくと親切

# 発表の概要

- 機能アノテーションってなに？
- 機能アノテーションはどうやってつけるの？
- パイプライン化 & ハイスループット化するには？

問題 機能アノテーションのように、  
いくつかの処理をつなげて、一連  
の処理としてまとめる手続きのこ  
とを、石油やガスの輸送に例えて、  
「パイプライン化」という。○か×  
か？

正解



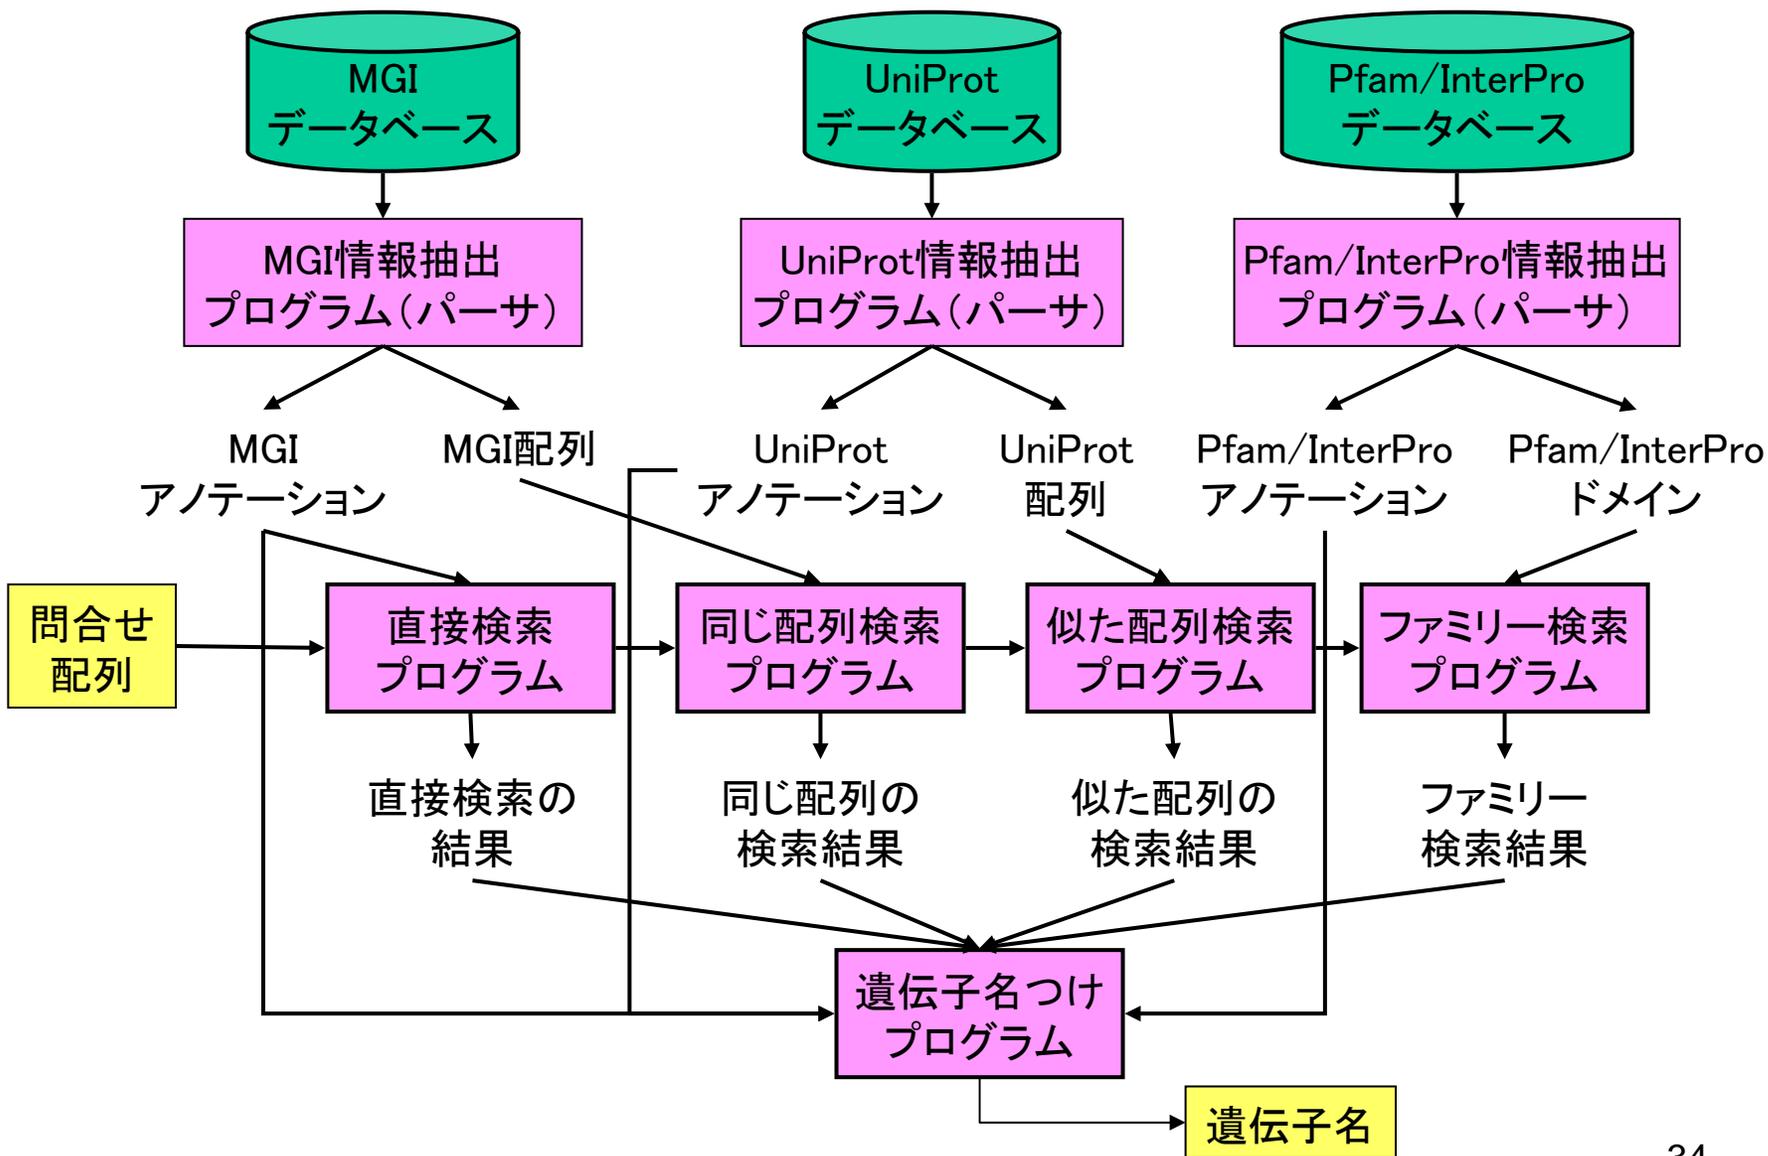
正解 ○

誰が見つけたかは不明だが、パイプライン化という  
最近は「ワークフロー(workflow)化」という場合も  
ある

# ハイスループット化

- 1個ずつなら手作業でも十分
- でも、たくさんの配列を対象とするのは、手作業では大変
- ではどうするか？
  
- 「自動」「パイプライン」化
  - 人手を必要としないようにする
  - 一連の複数の手続きを連続して一度に行うようにする

# 機能アノテーションパイプライン

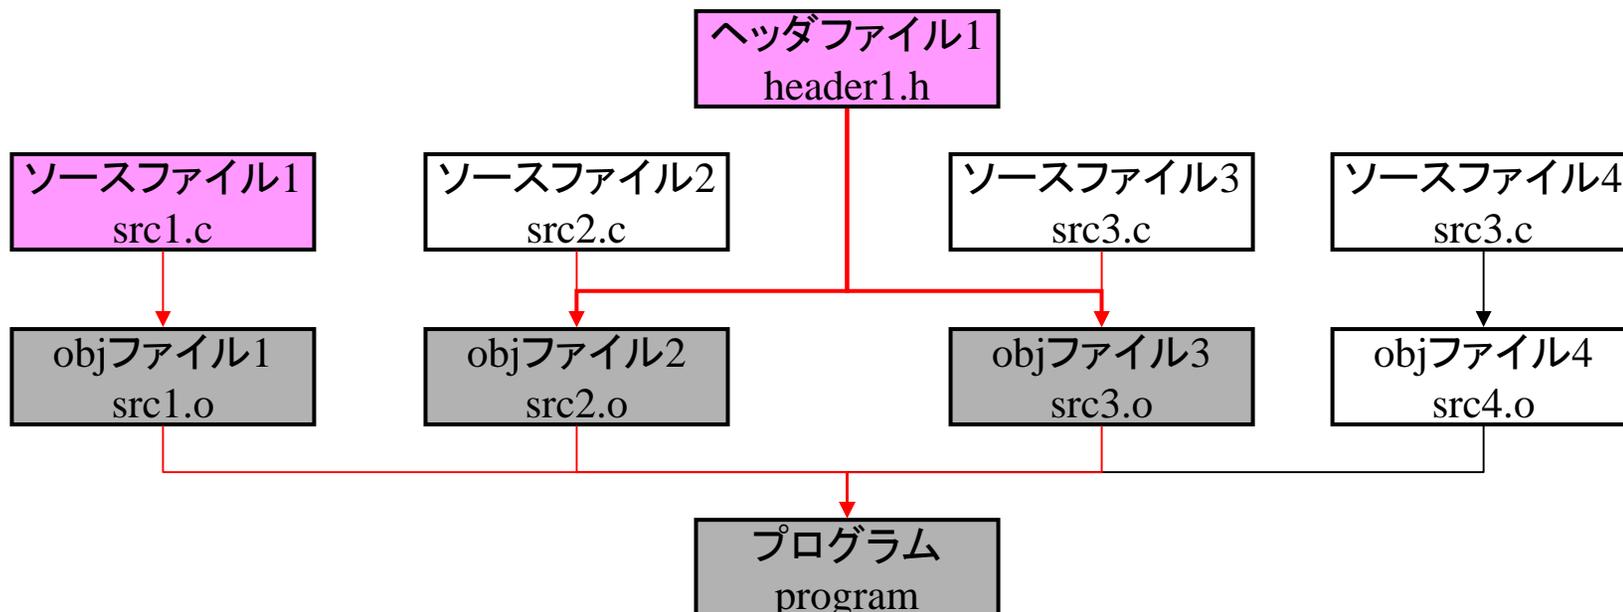


# 自動パイプライン化

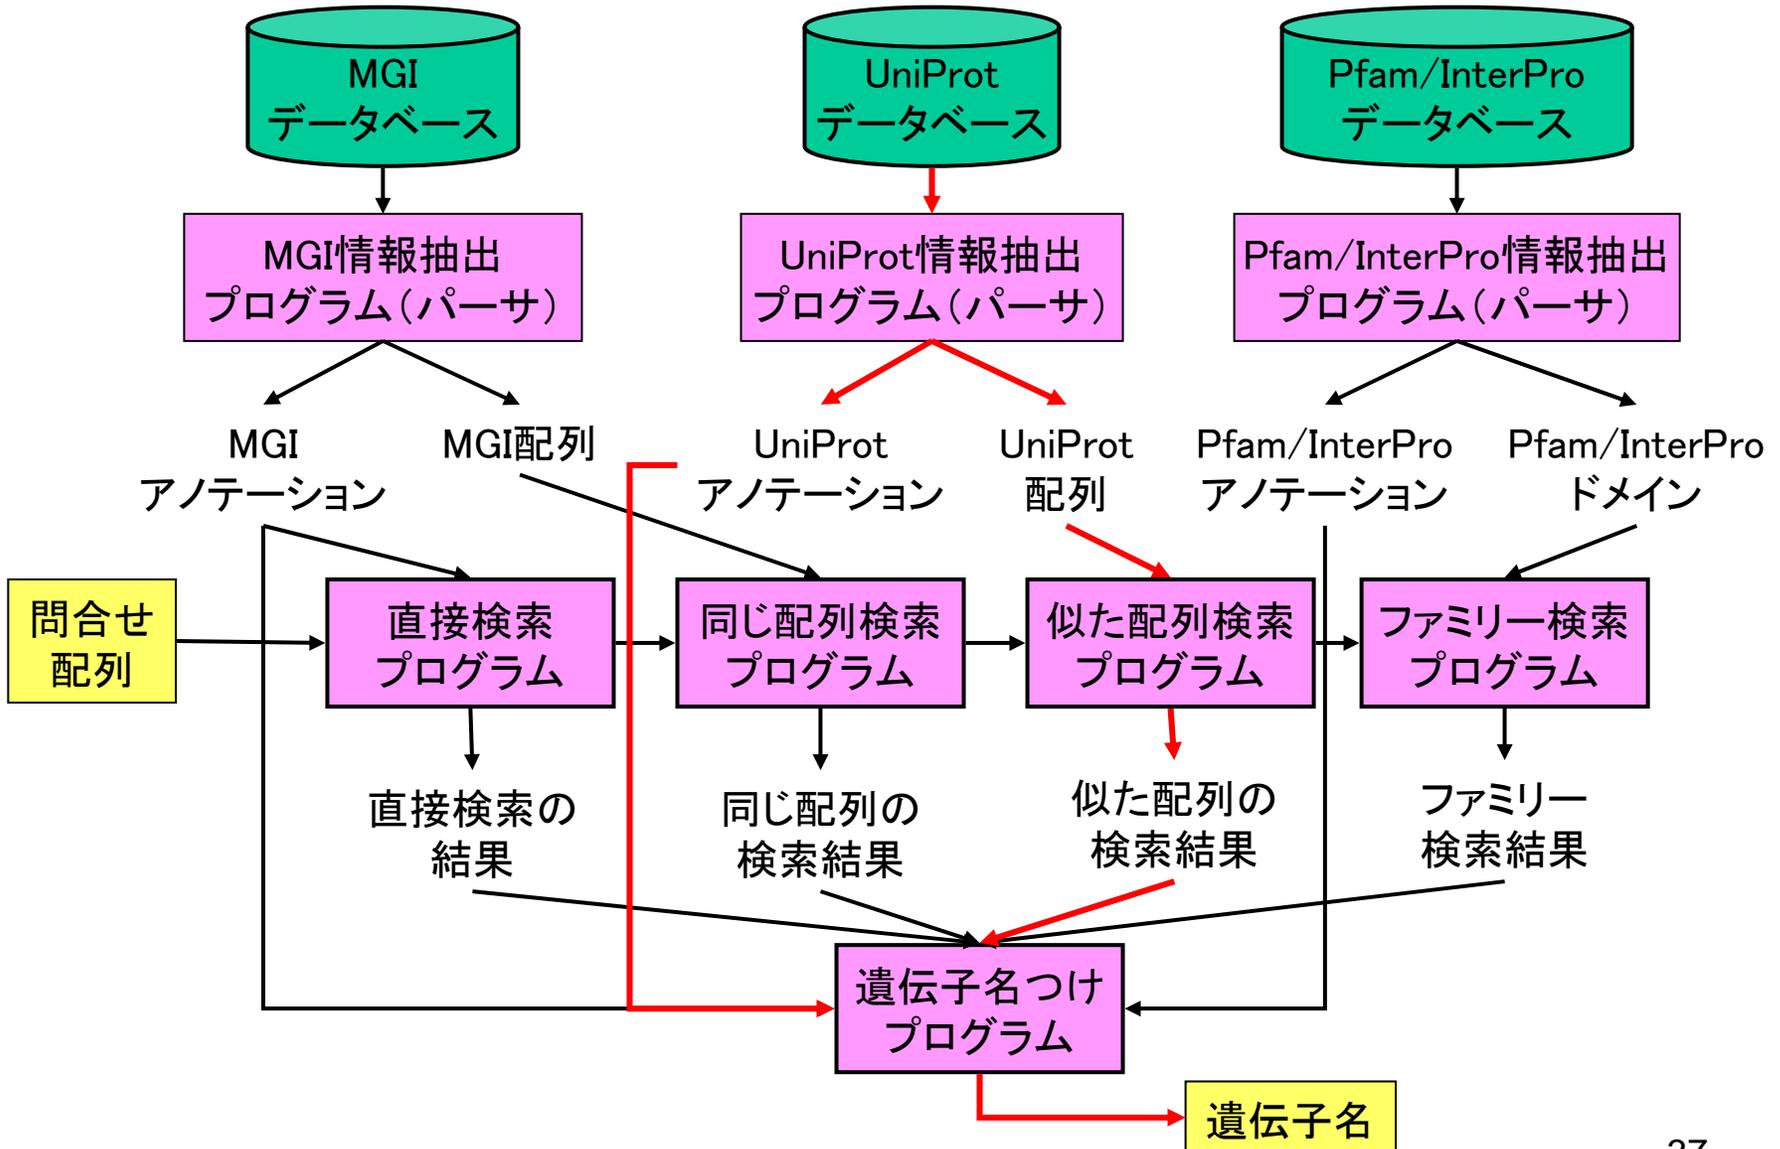
- 一般的な方法
  - パイプラインの各部を実行するプログラムを書く
    - Perl/Rubyなどでがしがし書く(bioperl/biorubyなどが便利)
  - 各部の処理を結合する
    - なんらかの (perlやshなどの)スクリプト言語で書く
    - makeコマンドを利用する

# makeコマンド

- 本来は、コンピュータプログラムの開発ツール
- 開発中にソースコードを変更したときに、変更の影響があった部分だけを再構築して、新しいプログラムを作り直すことができる。



# makeをパイプラインに応用



# makeの実行方法

- Makefileの作成
- “make”コマンドの実行

# 超簡易版Makefileテンプレート

```
all: finalfile1 finalfile2 ....
```

処理中に作られるファイル

```
finalfile1: sourcefile1.1 sourcefile1.2 ...
```

出カファイル

入カファイル

```
commandfile1 $^ > $@
```

ファイル生成コマンド

```
finalfile2: sourcefile2.1 sourcefile2.2 ...
```

```
commandfile2 $^ > $@
```

```
.....
```

# makeを使うとこんないいことが

- (先ほどいいましたが), 更新の影響のあるところだけ, 計算をやりなおすことができる。
  - パイプライン開発中は, スクリプト・プログラムの変更が頻繁におきるが, makeを使うと, その変更の影響があるデータだけを再計算(テスト)させるようにもできる
- “make -n” とすると, 実際に走らせる前に, ということが行われるかわかる
- “make -j 2” とするだけで, 並列処理させることもできる
- 使用方法が, 「どこどこのディレクトリに移動して, makeを実行する」だけなので, 仕事の引継ぎがとても楽

# まとめ

- 機能アノテーションとは
  - 主として配列に「機能情報」を付与すること
- 機能アノテーションのつけ方
  - 「データベース検索」「同じ配列の検索」「似た配列の検索」「ファミリーの検索」「機能未知」
- 機能アノテーションパイプラインの構築
  - makeが使えるかも

## さいごに

- 皆さんは「これから新しい仕事を始めよう」としているかと思いますが、
- その仕事を未来永劫続けるとは限らない
  - 次の仕事が残っているかもしれない
  - 次の職が残っているかもしれない
- 仕事の切り上げ方も考えておくと、後で幸せかもしれない(makeで楽になるかも)
- 以上ご清聴ありがとうございました。



# BLAST実行用Makefile

- seq/ の下にFASTA形式のファイルをおくと, results/ の下にBLAST計算結果が作られる
- 一度計算した配列は, 更新されるまで再計算されない

```
SEQFILES=$(wildcard seq/*)
RESULTFILES=$(SEQFILES:seq/%=results/%)

all: $(RESULTFILES)

results/%: seq/%
    blastall -p blastn -d refseq_rna $^ > $@
```