

できる！ BioPerl

infobiologist: 第二回研究集会(2003)@遺伝研

2003/1/28

大浦智紀

タカラバイオ株式会社

自己紹介


- タカラバイオ株式会社
- DNAチップ（1999年ころから）
 - 受託製造。
 - 自社製品企画。（コンテンツの準備）
 - プローブ設計。
 - 製造管理。
 - アノテーション。




Perlとの必然的な出会い。

Perlの導入

- 3000個の塩基配列のそれぞれに、PCR用プライマーを設計する。
- 3000個の遺伝子名のそれぞれについて、データベースを検索する。
- 市販アプリケーションでは難しい。



- 頼りになったPerl言語。しかし、自作プログラムを作るのは時間がかかる。




- bioperlを導入してみよう。

プログラムの基本形の構造

while ([読み込み]) {

[処理]

}



Perlプログラムの基本形

```
#!perl  
while($line = <>) {  
    print $line;  
}
```

sample01.pl

Perlプログラムの基本形

```
#!perl
```

```
#sample01.pl
```

```
while($line = <>) { #1行を$lineに読み込む。
```

```
    print $line; # $lineを出力する
```

sample01.pl

```
}
```

#whileは読み込み動作が真である場合ループ処理
を続ける。


perl SAMPLE01.PL < DATA.TXT

Bioperlとは

- すでに誰かが問題を解決している。
- データの形式やデータの取り扱い方法がパッケージとして提供されている。

<http://bioperl.org>

課題：データベースからデータ取得



データベースからデータ取得

```
#!perl
use Bio::DB::GenBank;
$gb = new Bio::DB::GenBank();
while($line = <>){
    chomp $line;
    $seq = $gb->get_Seq_by_acc($line);
}
```

sample02.pl

データ取得準備

```
#!perl  
use Bio::DB::GenBank;  
$gb = new Bio::DB::GenBank();  
while($line = <>){  
    chomp $line;  
    $seq = $gb->get_Seq_by_acc($line);  
}
```

データ取得と内容表示

```
#!perl
use Bio::DB::GenBank;
$gb = new Bio::DB::GenBank();
while($line = <>) {
    chomp $line;
    $seq = $gb->get_Seq_by_acc($line);
    print $seq->desc, "\n"; ★
} #while
```

sample03.pl

データ取得と内容表示2 (1 of 2)

```
#!perl  
use Bio::DB::GenBank;  
$gb = new Bio::DB::GenBank();  
while($line = <>){  
    chomp $line;  
    $seq = $gb->get_Seq_by_acc($line);
```


sample04.pl

データ取得と内容表示2 (2 of 2)

```
print $seq->desc, "\n";
print $seq->seq, "\n";
print $seq->length, "\n";
print $seq->primary_id, "\n";           Seq
print $seq->id, "\n";                 オブジェクトの内容表示
print '--\n';
} #while
```

sample04.pl

\$seqって何だ？



たくさんの属性を持つ

複数のSeqオブジェクト

SAMPLE04_local.plの出力。

desc:Mouse alpha-cardiac actin mRNA, 3' end.

length:1226

primary_id:NM_002401.2
desc:Homo sapiens clone 15e cytochrome P450 subfamily IIIA

polypeptide 43 (CYP3A43) mRNA, complete cds.

length:1512

primary_id:AF280108

id:AF280108

desc:Homo sapiens clone 15e cytochrome P450 subfamily IIIA

polypeptide 43 (CYP3A43) mRNA, complete cds.

length:1512

primary_id:11225237


id:AF280108

データ取得と内容表示2 (2 of 2)

```
print $seq->desc, "\n";
print $seq->seq, "\n";
print $seq->length, "\n";
print $seq->primary_id, "\n";           Seq
print $seq->id, "\n";                 オブジェクトの内容表示
print '--\n';
} #while
```

sample04.pl

オブジェクトを操作する



オブジェクトとメソッド

- メソッドの主な使い方は3つ
 - Seqオブジェクトを作る。
 - Seqオブジェクトを見る。
 - Seqオブジェクトの中身を変える。

メソッドの使い方 (1)

オブジェクトを自前で作る

```
$seq = Bio::Seq->new( -display_id => 'my_id',  
-seq => 'ATGCCGGTA');
```

オブジェクトを外から読みこんで作る

```
$seqio = Bio::SeqIO->new( '-format' => 'embl' , -file =>  
'myfile.dat'); #読み込み準備  
$seq = $seqio->next_seq();
```

メソッドの使い方 (2)

オブジェクトの中身を見る

```
print $seq->desc, "¥n";
```

メソッドの使い方 (3)

オブジェクトの中身を変える


```
print $seq->desc, "¥n";
```

```
$seq->desc( ‘hogehoge’ );
```

```
print $seq->desc, "¥n";
```

SAMPLE05_local.pl

オブジェクトを操作する



オブジェクトの操作

```
#!perl
use Bio::DB::GenBank;
$gb = new Bio::DB::GenBank();
while($line = <>) {
    chomp $line;
    $seq = $gb->get_Seq_by_acc($line);
    print $seq->desc, "\n";
} #while
```

オブジェクトとメソッドのまとめ

- メソッドの主な使い方は3つ
 - Seqオブジェクトを作る。
 - Seqオブジェクトを見る。
 - Seqオブジェクトの中身を変える。

Seqオブジェクトのメソッド

Methods		
new	Description	Code
seq	Description	Code
validate_seq	Description	Code
length	Description	Code
subseq	Description	Code
display_id	Description	Code
accession_number	Description	Code
desc	Description	Code
primary_id	Description	Code
can_call_new	Description	Code
alphabet	Description	Code
object_id	Description	Code
version	Description	Code
authority	Description	Code
homologous	Description	Code

\$seq->desc

\$seq->seq

\$seq->length

\$seq->accession_number

\$seq->primary_id

...

<http://doc.bioperl.org/releases/bioperl-1.2/>

クラスって何？（用語の整理）

- Seqクラスのオブジェクトが、Seqオブジェクトである。
- Bioperlは、バイオインフォマティクス用クラスのライブラリ。
- クラスの一覧表、使えるメソッド。
 - <http://doc.bioperl.org/releases/bioperl-1.2/>

Perlのお約束

```
#!perl
use Bio::DB::GenBank;
$gb = new Bio::DB::GenBank();
while($line = <>) {
    chomp $line;
    $seq = $gb->get_Seq_by_acc($line);
    print $seq->desc, "\n";
}
```

Perlのお約束


```
#!/perl -w
use strict;
use vars qw($gb);
use Bio::DB::GenBank;
$gb = new Bio::DB::GenBank();
while( defined (my $line = <>) ) {
    chomp $line;
    my $seq = $gb->get_Seq_by_acc($line);
    print $seq->desc, "\n";
}
exit;
```

お約束の意味

```
#!perl -w #1回しか出現しない変数などいろいろとチェック。
use strict; #構文を制限
use vars qw($gb); #グローバル変数
use Bio::DB::GenBank;
$gb = new Bio::DB::GenBank();
while( defined(my $line = <>) ) { #ローカル変数、入力確認
    chomp $line;
    my $seq = $gb->get_Seq_by_acc($line); #ローカル変数
    print $seq->desc, "\n";
}
exit; #プログラムの終了
```

なぜ約束があるの？

- スペルミスのチェックを自動的にしてもらえる。
- 文法チェック。
- 変数のグローバル／ローカル。



- プログラムの規模が大きくなるのに備える。

Batch Entrez

Entrez-Nucleotide - Microsoft Internet Explorer

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

戻る 検索 お気に入り メディア
アドレス(D) http://www.ncbi.nlm.nih.gov/entrez/batchentrez.cgi?db=Nucleotide

Google ウェブ検索 サイト検索 カテゴリ ページ情報 上へ

NCBI PubMed Nucleotide Protein Genome Structure PMC

Database Nucleotide File: 参照... Retrieve

About Entrez

Search for Genes: LocusLink provides curated information for human, fruit fly, mouse, rat, and zebrafish


Batch Entrez

Batch Entrez has changed!

You will need Batch Entrez now only to upload a file of GI or accession numbers for an Entrez search. You can do all other large searches directly within Entrez.

何でもPerlでやらなくてよい。

パーサを作る

- パーサって何?
 - Parser, Parseする。
 - 構文解析。
 - SeqIOクラス
 - フォーマット変換ツール
 - GenBankパーサ
 - BLASTパーサ
 - ○○パーサ
- 
- 見ていきます。

GenBank -> Fasta変換プログラム

```
#!perl -w
use strict;
use Bio::SeqIO;
use vars qw($in $out);
$in = Bio::SeqIO->new(
    -fh => \$*STDIN , -format => 'GenBank' );
$out = Bio::SeqIO->new(
    -fh => \$*STDOUT , -format => 'Fasta' );
while(my $seq = $in->next_seq) {
    $out->write_seq($seq);
}
exit;
```

SeqIO オブジェクト作成

sample06_gb2fasta.pl

SeqIOオブジェクト

```
$in = Bio::SeqIO->new(  
    -fh => *STDIN , -format =>  
    'GenBank' );  
  
$out = Bio::SeqIO->new(  
    -fh => *STDOUT , -format =>  
    'Fasta' );
```

ファイルハンドル:

標準入力, 標準出力

GenBank -> Fasta 出力部分

```
#!perl -w
use strict;
use Bio::SeqIO;
use vars qw($in $out);
$in = Bio::SeqIO->new(
    -fh => \$*STDIN , -format => 'GenBank' );
$out = Bio::SeqIO->new(
    -fh => \$*STDOUT , -format => 'Fasta' );
while(my $seq = $in->next_seq) {
    $out->write_seq($seq);
}
exit;
```

sample06_gb2fasta.pl

GenBank flatfileのパス (1 of 2)

```
LOCUS AA056154          582 bp mRNA Linear EST 02-FEB-1997
DEFINITION ZF55-12.11 soares retina N2b4HR Homo sapiens cDNA clone
IMAGE:380878 5' similar to gb:K02281_cds1 RHODOPSIN (HUMAN);, mRNA
ACCESSION AA056154
VERSION AA056154.1 GI:1548492
KEYWORDS EST.
SOURCE Homo sapiens (human).
ORGANISM Homo sapiens
Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Euteleostomi;
Mammalia; Eutheria; Primates; Catarrhini; Hominidae; Homo.
REFERENCE
AUTHORS Hillier,L., Lennon,G., Becker,M., Bonaldo,M.F., Chiapelli,B.
TITLE Generation and analysis of 280,000 human expressed sequence tags
JOURNAL Genome Res. 6 (9), 807-828 (1996)
MEDLINE 97044478
PUBMED 8889549
COMMENT Contact: Wilson RK Washington University School of Medicine 4444
Forest Park Parkway, Box 8501, St. Louis, MO 63108 Tel: 314 286
...
FEATURES
source      Location/Qualifiers
1..582
/dev_stage="55 year old"
/tissue_type="retina" .....
```

GenBankのベース (2 of 2)

COMMENT Original source text: Mouse cardiac muscle, cDNA to mRNA, clone pmC1. Draft entry and computer-readable sequence for [1] kindly provided by D.P.Leader, 27-MAY-1987.
FEATURES
source Location/Qualifiers
 1..1226 /organism="Mus musculus"
 /db_xref="taxon:10090"
 <1..>1226 /note="actin mRNA [1]"
 <1..1128 /protein_id="AAA37167.1"
 /codon_start=1 /translation="DDEETTALVCDNGSGLVKAGFAGDDAPRAVFPSIVGRPRHQGVM
 VGMGQKDSYVGDEAQSKRGILTLYKPIEHGIITNWDDMEKIWHHTFYNELRVAPEEHP
 TLLTEAPLNPKANREKMTQIMFETFNVPAMYVAIQAVLSLYASGRTTGIVLDSGDGVT
 HNVPPIYEGYALPHAIMRLDLAGRDLTDYLMKILTERGYSFVTTAEREIVRDIKEKLCY
 VALDFENEMATAASSSSLEKSYELPDGQVITIGNERFRCPETLFQPSFIGMESAGIHE
 TTYN SIMKCDIDIRKDLYANNVLSGGTTMYPGIADRMQKEITALAPSTMKIKIAAPPE
 RKYSVWIGGSILASLSTFQQMWISKQEYDEAGPSIVHRKCF"
 /db_xref="GI:387090" /note="alpha-cardiac actin"
BASE COUNT 286 a 346 c 294 g 300 t
ORIGIN

GenBankリポーサ

```
#!/perl -w
use strict;
use Bio::SeqIO;
use vars qw($in $out);
$in = Bio::SeqIO->new(-fh => \*STDIN , -format =>
    'GenBank');
while(my $seq = $in->next_seq) {
    print 'display_id:', $seq->display_id, "\n";
    print 'desc:', $seq->desc, "\n";
    print 'accession:', $seq->accession_number, "\n";
    print 'length:', $seq->length, "\n";
    print "----\n";
```

属性を表示する。

```
}
```

```
exit;
```

sample07_gb.pl


GenBank パーサ feature付き

```
#!/perl -w
use strict;
use Bio::SeqIO;
use vars qw($in $out);
$in = Bio::SeqIO->new(-fh => \*STDIN , '-format' => 'GenBank');
while(my $seq = $in->next_seq) {
    print 'desc:', $seq->desc, "\n";                                属性を表示する。
    my @feature_array = $seq->get_SeqFeatures;
    foreach my $feat (@feature_array) {
        my $primary_tag = $feat -> primary_tag();
        my $start = $feat -> start;
        my $end = $feat -> end;
        print ("$primary_tag:$primary_tag, $start, $end\n");
    }#for each feature
    print "----\n";
}
exit;
```

sample08_gb_feat.pl

get_seqFeaturesメソッド

@feature_array = \$seq->get_SeqFeatures;



```
Title   : get_SeqFeatures
Usage   :
Function: Get the feature objects held by this feature holder.
          Features which are not top-level are subfeatures of one or
          more of the returned feature objects, which means that you
          must traverse the subfeature arrays of each top-level
          feature object in order to traverse all features associated
          with this sequence.
          Use get_all_SeqFeatures() if you want the feature tree
          flattened into one single array.


Example :
>Returns : an array of Bio::SeqFeatureI implementing objects
Args    : none
At some day we may want to expand this method to allow for a feature
filter to be passed in.
```

メソッドが何
を返すのか。

配列とは

- 複数の要素を持つ変数。

@feature_array のイメージ




feature配列の中身にアクセス

```
foreach my $feat (@feature_array) {  
    my $primary_tag = $feat->primary_tag();  
    my $start = $feat->start;  
    my $end = $feat->end;  
    print ("$primary_tag:$primary_tag, $start, $end\n");  
} #for each feature
```

@feature_array

CDS	RNA	gene	Source
-----	-----	------	--------

それぞれの\$featに対して
メソッドで中身を見る。



GenBank パーサ feature付き

```
#!/perl -w
use strict;
use Bio::SeqIO;
use vars qw($in $out);
$in = Bio::SeqIO->new(-fh => \*STDIN , '-format' => 'GenBank');
while(my $seq = $in->next_seq) {
    print 'desc:', $seq->desc, "\n";                                属性を表示する。
    my @feature_array = $seq->get_SeqFeatures;
    foreach my $feat (@feature_array) {
        my $primary_tag = $feat -> primary_tag();
        my $start = $feat -> start;
        my $end = $feat -> end;
        print ("$primary_tag:$primary_tag, $start, $end\n");
    }#for each feature
    print "----\n";
}
exit;
```

sample08_gb_feat.pl

GenBankのベースのまとめ (1)

LOCUS AA056154 582 bp mRNA Linear EST 02-FEB-1997
DEFINITION ZF55-12.11 soares retina N2b4HR Homo sapiens cDNA clone
IMAGE:380878 5' similar to gb:K02281_cds1 RHODOPSIN (HUMAN);, mRNA
ACCESSION AA056154
VERSION AA056154.1 GI:1548492
KEYWORDS EST.
SOURCE Homo sapiens (human).
ORGANISM Homo sapiens
Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Euteleostomi;
Mammalia; Eutheria; Primates; Catarrhini; Hominidae; Homo.
REFERENCE 1 (bases 1 to 582)
AUTHORS Hillier,L., Lennon,G., Becker,M., Bonaldo,M.F., Chiapelli,B.
TITLE Generation and analysis of 280,000 human expressed sequence tags
JOURNAL Genome Res. 6 (9), 807-828 (1996)
MEDLINE 97044478
PUBMED 8889549
COMMENT Contact: Wilson RK Washington University School of Medicine 4444
Forest Park Parkway, Box 8501, St. Louis, MO 63108 Tel: 314 286
...
FEATURES source Location/Qualifiers
1..582
/dev_stage="55 year old"
/tissue_type="retina" ...

値を取り出すメソッドが用意
されている。

Bio::SeqFeatureI オブジェクトのメソッド(1)

- \$feat → primary_tag;
 - primary tagを返す。(CDS, mRNA, geneなどの文字列。)
- \$feat → start
 - featureのスタート位置を返す。
- \$feat → end
 - featureの終了位置を返す。

GenBank パーサ feature付きその2 (1 of 2)

```
#!perl -w
use strict;
use Bio::SeqIO;
use vars qw($in $out);
$in = Bio::SeqIO->new(-fh => \*STDIN , '-format' =>
    'GenBank');
while(my $seq = $in->next_seq) {
    print 'desc:', $seq->desc, "\n";
    my @feature_array = $seq->all_SeqFeatures;
    foreach my $feat (@feature_array) {
        my $primary_tag = $feat -> primary_tag();
        my $start = $feat -> start;
        my $end = $feat -> end;           sample09_gb_feat.pl
        print ("$primary_tag:$primary_tag, $start, $end\n");
    }
}
```

GenBank パーサ feature付きその2 (2 of 2)

```
foreach my $each_tag ($feat->get_all_tags()) {  
    my @tag_values = $feat-  
    >each_tag_value($each_tag);  
    print ("$each_tag:$each_tag, ");  
    print (@tag_values"\n");  
} #for each tag  
} #for each feature  
print "----\n";  
} #while  
exit;
```

sample09_gb_feat.pl

Bio::SeqFeatureI オブジェクトのメソッド(2)

- \$feat->get_all_tags
 - すべてのタグを配列で返す。
- \$feat->each_tag_value(\$tag)
 - 指定したタグの値を配列で返す。

GenBankのパースのまとめ（その2）

複数のfeatureを配列として取り出す。

```
COMMENT Original source text: Mouse cardiac muscle, cDNA to mRNA, clone pmC1. Draft entry and computer-readable sequence for [1] kindly provided by D.P.Leader, 27-MAY-1987.  
FEATURES  
source  
mRNA  
CDS  
$feat->primary_id featureの名前を取りだす。  
BASE COUNT 286 a 346 c 294 g 300 t  
ORIGIN 1 ...  
/organism="Mus musculus"  
/db_xref="taxon:10090"  
<1..>1226  
/note="actin mRNA [1]"  
<1..1128  
/protein_id="AAA37167.1"  
/codon_start=1  
/translation="DDETTALVCDNGSGLVKAGFAGDDAPRAVFPSIVGRPRHGGVIVG  
MGQKDSYVGDEAQSKRGILTLKYPIEHGIITNWDDMEKIWHHTFYMLRVAPPEHP  
TLLTEAPLNPKANREKMTQIMFETFNVPAMYVAIQAVLSLYASGRTTGIVLDRGIVGT  
HNVIYEGYALPHAIMRLDLAGRDLTDYLMKILTERGSFVTAAEREIADTIKEKCY  
VALDFENEMATAASSSSLEKSYELPDGQVITIGNERFRCPETLFQPSRIGM  
TTYN SIMKCDIDIRKDLYANNVLSGGTTMYPGIADRMQKEITALAPS  
RKYSVWIGGSILASLSTFQQMWISKQEYDEAGPSIVHRKCF"  
/db_xref="GI:387090"
```

start/endを取り出す。

} each_tag, tag_valueの組み合わせで取り出す。

本日のまとめ

- **While**を使って繰り返し処理を行う。
- **Bioperl**を使ってデータをダウンロードしたり、パースしたり、フォーマット変換したりできる。
- Bioperlを扱うということは**オブジェクト**を扱うということである。

本日のまとめ(細かいこと)

- ・最も重要なクラスは、**Seq**, **SeqIO**, **SeqFeatureI**クラスである。
- ・オブジェクトは**メソッド**によって、(属性の値を)参照したり、変更したりできる。
- ・メソッドによって返されるものはいろいろ。
 - 値
 - オブジェクト
 - オブジェクトのリスト

プログラムを作ってみる

- 簡単なものから作る。
- 必要に応じて作る。
- あれば便利、を考える。
- とりあえずサンプルプログラムを拡張していく。
- Bioperlのオブジェクトは少しずつ、必要に応じて覚えていく。

サンプルプログラム

- bioperl-1.2/scripts
- bioperl-1.2/examples

パッケージを解凍したディレクトリに入っている。

チュートリアル

- bioperl-1.2/bptutorial.pl

パッケージを解凍したディレクトリに入っている。
- <http://www.pasteur.fr/recherche/unites/sis/formation/bioperl/>

パストール研究所のチュートリアル。

より進んだ学習のために

- Perlを基礎から勉強したい。
- 複雑なデータ型を使いたい。
- オブジェクト指向をより深く理解したい。
- 仕事に必要な新しいクラスを自由に作りたい。
- 大量のデータを高速にアクセスしたい。

作業環境整備に

初心者でもわかる!
バイオインフォマティクス入門—
やさしいUNIX操作から遺伝子・
タンパク質解析まで
坊農 秀雅(著)
出版社: 羊土社
ISBN: 489706290X

- bioperlのインストール
- 各種プログラムのインストール。

Perlの勉強

Perl言語プログラミングレッスン 入門編

結城 浩 (著)

出版社: ソフトバンクパブリッシング ;

ISBN: 4797312211

- プログラムの初心者から。
- 丁寧な解説。

Perlのリファレンス

プログラミングPerl〈VOLUME1〉
ラリー ウオール(著), ジョン オーワント(著), トム ク
リスチャンセン(著), 近藤 嘉雪(翻訳)
出版社: オライリー・ジャパン;
ISBN: 4873110963

- リファレンスとして。
- 初心者には言い回し
が難しい。

Perlのプログラム事例集

Perlクックブック—Perlの鉄人が贈るレシピ集
トム クリスチャンセン(著), ネイザントーキントン
(著), 田和 勝(翻訳)
出版社: オライリー・ジャパン;
ISBN: 4873110378

- データベースアクセス。
- ほかのプログラムと
の協調。
- CGI

複雑なデータ型を扱いたい

Effective Perl ASCII Addison Wesley
Programming Series
ジョセフ・N. ホール (著), ランドル・L. シュウォーツ
(著), 吉川 邦夫 (翻訳)
出版社: アスキー ; ISBN: 4756130577

- 配列、ハッシュ。
- リファレンス、デリファレンス
- 配列の配列、ハッシュの配列。
- 複雑なソート。
- オブジェクト指向。

モジュールの使い方を知りたい

Perlモジュール活用ガイド—
かんたんオブジェクト指向プログラミング
エリック フォスター・ジョンソン (著), Eric
Foster-Jonson (原著), アークシンクタンク
(翻訳), 三島 俊司
出版社: 翔泳社
ISBN: 4881356682

- モジュールのインストール。
- 標準的なモジュールの使い方。

大量のデータを扱いたい

入門Perl DBI

アリゲータ デカルト (著), ティム バンス (著),
Alligator Descartes (原著), Tim Bunce (原著),
田中 幸 (翻訳)

出版社: オライリー・ジャパン

ISBN: 4873110505

- 大量のデータをディスクに保存して、後からアクセスしたい。
- データベースシステムをPerlから使いたい。
- データベースってどんなもの？