

```
#!/usr/bin/env ruby
```

```
require 'bio'
```

# BioRuby

片山 俊明, 五斗 進

京大化研バイオインフォマティクスセンター



informatics  
BioRuby.org

# BioRuby プロジェクトとは

- 国産の優れたオブジェクト指向スクリプト言語 Ruby を使って、Bioinformatics の面倒なルーチンワークを再利用できる形でライブラリ化する
  - 生物学者がいつもの仕事をサラッと片付けられる
    - ・ データベースからエントリを取ってきてパースする
    - ・ Blast をガンガン流して結果を回収する
- 海外の先行プロジェクト BioPerl, BioJava, BioPython 等と比較しての利点
  - Ruby という言語が高機能で使いやすい、短く書ける
  - 開発コミュニティが日本語を話す

# Open Bio\*

- O|B|F -- Open Bio Foundation
  - バイオインフォマティクスに関するオープンソースコミュニティ
- **BioRuby**
- BioPerl
- BioPython
- BioJava
- BioDAS
- BioMOBY
- EMBOSS
- Ensembl
- OmniGene
- GMOD
- Apollo
- OBDA
- BioCaml
- BioLisp
- BioConductor
- BioPathways
- BioBlog
- BioCyc
- BioDog
-

# OBDA

- BioHackathon

- 2002/01 Arizona, 2002/02 Cape Town
- どの Open Bio\* ライブラリで作成したデータベースも共通にアクセスできる
- 競合ではなく協調 Open Bio\* ハッカーは仲間です:-)

# OBDA

- BioHackathon

- 2002/01 Arizona, 2002/02 Cape Town
- どの Open Bio\* ライブラリで作成したデータベースも共通にアクセスできる



# OBDA

- BioHackathon
  - 2002/01 Arizona, 2002/02 Cape Town
  - どの Open Bio\* ライブラリで作成したデータベースも共通にアクセスできる
  - 競合ではなく協調 Open Bio\* ハッカーは仲間です:-)
- Open Bio\* Sequence Database Access
  - Directory Registry (Stanza)
  - Flat File indexing (DBM, BDB)
  - BioFetch (CGI/HTTP)
  - BioSQL (MySQL, PostgreSQL, Oracle)
  - SOAP (XEMBL based)
  - BioCORBA (BSANE compliant)

# OBDA を使ったエントリ取得

- 設定ファイル (Stanza フォーマット)
  - ~/.bioinformatics/seqdatabase.ini
  - /etc/bioinformatics/seqdatabase.ini
  - <http://open-bio.org/registry/seqdatabase.ini>

```
[swissprot]
protocol=biosql
location=db.bioruby.org
dbname=biosql
driver=mysql
biodbname=sp
```

```
[embl]
protocol=biofetch
location=http://bioruby.org/cgi-bin/biofetch.rb
biodbname=embl
```

```
:
```

# OBDA を使ったエントリ取得

- 設定ファイル (Stanza フォーマット)

- ~/.bioinformatics/seqdatabase.ini
- /etc/bioinformatics/seqdatabase.ini
- <http://open-bio.org/registry/seqdatabase.ini>

```
[swissprot]
protocol=biosql
location=db.bioruby.org
dbname=biosql
driver=mysql
biodbname=sp
```

```
[emb1]
protocol=biofetch
location=http://bioruby.org/cgi-bin/biofetch.rb
biodbname=emb1
```

:

```
#!/usr/bin/env ruby
require 'bio'
```

```
reg = Bio::Registry.new
db = reg.db("swissprot")
entry = db.fetch("TETW_BUTFI")
```



# BioRuby にできること

- Bio::Sequence, Bio::Location, Bio::Feature クラス
  - 塩基配列、アミノ酸配列の取り扱い
  - 組成、スプライシング、翻訳、ウィンドウサーチなど
- Bio::DB クラス
  - データベースのパパーザ (現在 20 種くらい)
- Bio::Blast, Bio::Fasta クラス
  - Blast/Fasta を実行し結果をパースするファクトリ
- Bio::PubMed, Bio::Reference クラス
  - 文献データベース検索、BibTeX などのフォーマッタ
- Bio::Registry, Bio::SQL, Bio::Fetch, Bio::FlatFile クラス
  - データベース入出インターフェイス (OBDA 準拠)
- Bio::Pathway, Bio::Relation クラス
  - グラフ、2 項関係の演算

# 初めて実行するプログラム

```
#!/usr/bin/env ruby
```

```
require 'bio'
```

```
gene = Bio::Seq::NA.new("catgaattattgtagannntgataaagacttgac")
```

```
prot = gene.translate
```

```
puts prot.split('X').join(' ').capitalize.gsub(/¥*/, 'o') << '!'
```

# 初めて実行するプログラム

```
#!/usr/bin/env ruby
```

```
require 'bio'
```

```
gene = Bio::Seq::NA.new("catgaattattgtagannntgataaagacttgac")
```

```
prot = gene.translate → "HELL*XW*RLD"
```

```
puts prot.split('X').join(' ').capitalize.gsub(/¥*/, 'o') << '!'
```

# 初めて実行するプログラム

```
#!/usr/bin/env ruby
```

```
require 'bio'
```

```
gene = Bio::Seq::NA.new("catgaattattgtagannntgataaagacttgac")
```

```
prot = gene.translate
```

```
puts prot.split('X').join(' ').capitalize.gsub(/¥*/ , 'o') << '!'
```

```
→ ["HELL*", "W*RLD"]
```

# 初めて実行するプログラム

```
#!/usr/bin/env ruby
```

```
require 'bio'
```

```
gene = Bio::Seq::NA.new("catgaattattgtagannntgataaagacttgac")
```

```
prot = gene.translate
```

```
puts prot.split('X').join(' ').capitalize.gsub(/¥*/, 'o') << '!'
```

→ "HELL\* W\*RLD"

# 初めて実行するプログラム

```
#!/usr/bin/env ruby
```

```
require 'bio'
```

```
gene = Bio::Seq::NA.new("catgaattattgtagannntgataaagacttgac")
```

```
prot = gene.translate
```

```
puts prot.split('X').join(' ').capitalize.gsub(/¥*/, 'o') << '!'
```

→ "Hell\* w\*rld"

# 初めて実行するプログラム

```
#!/usr/bin/env ruby
```

```
require 'bio'
```

```
gene = Bio::Seq::NA.new("catgaattattgtagannntgataaagacttgac")
```

```
prot = gene.translate
```

```
puts prot.split('X').join(' ').capitalize.gsub(/¥*/, 'o') << '!'
```

→ "Hello world"

# 初めて実行するプログラム

```
#!/usr/bin/env ruby
```

```
require 'bio'
```

```
gene = Bio::Seq::NA.new("catgaattattgtagannntgataaagacttgac")
```

```
prot = gene.translate
```

```
puts prot.split('X').join(' ').capitalize.gsub(/¥*/, 'o') << '!'
```

→ Hello world!



# コード比較

- FASTA ファイルを BioRuby で読み込む

```
#!/usr/bin/ruby
```

```
require 'bio'
```

```
flatfile = Bio::FlatFile.open(Bio::FastaFormat, 'filename')
```

```
flatfile.each do |entry|
```

```
  puts entry.entry_id
```

```
  puts entry.seq
```

```
  puts entry
```

```
end
```

- FASTA ファイルを BioPerl で読み込む

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

```
use Bio::SeqIO;
```

```
my $seqio = new Bio::SeqIO(-format => 'fasta',  
                           -file => 'filename');
```

```
while ( my $entry = $seqio->next_seq ) {  
    print $entry->display_id, "\n";  
    print $entry->seq, "\n";  
    print ">", $entry->desc, "\n", $entry->seq, "\n";  
}
```

- FASTA ファイルを BioPython で読み込む

```
#!/usr/bin/python
```

```
from Bio import Fasta
```

```
iter = Fasta.Iterator(open('filename'), Fasta.RecordParser())
```

```
while 1:
```

```
    entry = iter.next()
```

```
    if not(entry): break
```

```
    print entry.title
```

```
    print entry.sequence
```

```
    print entry
```

# コード比較

- BioRuby で Blast を local に実行

```
#!/usr/bin/ruby
```

```
require 'bio'
```

```
blast = Bio::Blast.local('blastp', 'hoge.pep')
```

```
flatfile = Bio::FlatFile.open(Bio::FastaFormat, 'queryfile')
```

```
flatfile.each do |seq|
```

```
  result = blast.query(seq)
```

```
  result.each do |hit|
```

```
    puts hit.query_id, hit.target_id, hit.evalue if hit.evalue < 0.05
```

```
  end
```

```
end
```

- BioPerl で Blast を local に実行

```
#!/usr/bin/perl

use Bio::SeqIO;
use Bio::Tools::Run::StandAloneBlast;
use Bio::Tools::BPlite;

my @params = ('program' => 'blastp', 'database' => 'hoge.pep');
my $factory = Bio::Tools::Run::StandAloneBlast->new(@params);

my $input = Bio::SeqIO->new(-format => 'fasta', -file => "queryfile");

while ( my $seq = $input->next_seq ) {
    $result = $factory->blastall($seq);
    while ( my $hit = $result->nextSbjct ) {
        while ( my $hsp = $hit->nextHSP ) {
            print $result->query, $hit->name, $hsp->P, "\n" if $hsp->P < 0.05;
            last;
        }
    }
}
```

- BioPython で Blast を local に実行

```
#!/usr/bin/python
```

```
from Bio import Fasta
```

```
from Bio.Blast import NCBIStandalone
```

```
iterator = Fasta.Iterator(open("queryfile"), Fasta.RecordParser())
```

```
while 1:
```

```
    query = iterator.next()
```

```
    if not(query): break
```

```
    open("query.fst", "w").write(str(query))
```

```
    out, error = NCBIStandalone.blastall("blastall", "blastp", "hoge.pep", "query.fst")
```

```
    parser = NCBIStandalone.BlastParser()
```

```
    result = parser.parse(out)
```

```
    for alignment in result.alignment:
```

```
        for hsp in alignment.hsps:
```

```
            if hsp.expect < 0.05:
```

```
                print query.title, alignment.title, hsp.expect
```

# いまからの課題

- ドキュメント
- SOAP(DAS, XEMBL, 遺伝研), CORBA アクセスの整備
- HMMER, EMBOSS, ClustalW, T-Coffee など対応
- PDB - 構造系のデータベースクラス、メソッドの開発
- PATHWAY, SSDB, KO, GO, InterPro
- BioFetch で Entrez E-utils 対応
- GFF, AGAVE, GAME フォーマット
- 配列データベース系クラスのリファクタリング
- アライメントクラス

# BioRuby.org

- 総合情報 <http://bioruby.org/>
  - 開発情報 <http://ura.bioruby.org/>
  - ニュース <http://q--p.bioruby.org/>
  
  - ソース <ftp://bioruby.org/>
  - CVS <cvs.bioruby.org>
  
  - M L [ja@bioruby.org](mailto:ja@bioruby.org), [dev@bioruby.org](mailto:dev@bioruby.org)
  - 問い合わせ [staff@bioruby.org](mailto:staff@bioruby.org)
- presentation by T. Katayama <[k@bioruby.org](mailto:k@bioruby.org)>