

BioPerl tutorial

Università di Roma “La Sapienza”
Master di Bioinformatica

Andrea Sterbini

Installazione

- A mano
 - > `tar xzvf bioperl-1.4.tar.gz`
 - > `cd bioperl-1.4`
 - > `perl Makefile.PL`
 - > `make`
 - > `make test`
 - > `make install`
- Con CPAN
 - > `cpan`
 - > `install Bundle::BioPerl`
 - > `install Bio::Perl`
 - Gestisce i prerequisiti
 - Necessaria la connessione a Internet
 - Oppure (MINI)CPAN
- Moduli aggiuntivi
 - Bioperl-run e Bioperl-ext (applicazioni esterne)
 - **PISE, EMBOSS, pSW, clustalw, NCBI-blast, TCoffee**
 - Bioperl-db (accesso a database locali)
 - **Mysql, Postgres, Oracle**
 - Altri package dal repository CVS di bioperl.org
 - **bioperl-microarray, bioperl-pedigree, bioperl-gui, bioperl-pipeline, bioperl-das-client, bioperl-corba-client**

Per ottenere la documentazione: `perldoc <modulo bioperl>`
Esempio: `perldoc Bio::SeqIO`

Sequenze

- Seq
 - PrimarySeq
 - LocatableSeq
 - RelSegment
 - LiveSeq
 - LargeSeq
 - RichSeq
 - SeqWithQuality
 - (SeqI)
- Locations
- SeqIO

- Creazione da stringa

```
use Bio::Seq;  
$seq = Bio::Seq->new(  
    -seq          => 'actgtggcgtcaact',  
    -desc         => 'Sample Bio::Seq object',  
    -display_id   => 'qualcosa',  
    -accession_number=> 'accnum',  
    -alphabet     => 'dna' );
```

- I/O da file e trasformazione di formato

```
use Bio::SeqIO;  
$in  = Bio::SeqIO->new(  
    -file => "inputfilename", -format => 'Fasta');  
$out = Bio::SeqIO->new(  
    -file => ">outputfilename", -format => 'EMBL');  
while ( my $seq = $in->next_seq() ) {  
    $out->write_seq($seq); }
```

Input da database in rete

- Database in rete
 - Genbank
 - NCBI
 - Genpept
 - RefSeq
 - Swissprot
 - EMBL
 - Ma anche
 - Ace
 - SWALL
- Collegamento al database Genbank

```
use Bio::DB::GenBank;
$gb = new Bio::DB::GenBank();
```
 - Scaricare una sequenza conoscendone lo ID

```
$seq1 = $gb->get_Seq_by_id( 'MUSIGHBA1' );
```
 - Scaricare una sequenza conoscendone l'Accession code

```
$seq2 = $gb->get_Seq_by_acc( 'AF303112' );
```
 - Apertura di uno stream su tre sequenze

```
$seqio = $gb-> get_Stream_by_id(["J00522",
"AF303112","2981014"]);
```

Sequenze ...

- Metodi di base
 - ID della sequenza
`$seqobj->display_id();`
 - Stringa della sequenza
`$seqobj->seq();`
 - Sottosequenza
`$seqobj->subseq(5,10);`
 - Accession number
`$seqobj->accession_number();`
 - Alfabeto 'dna','rna','protein'
`$seqobj->alphabet();`
 - ID unico
`$seqobj->primary_id();`
 - Descrizione
`$seqobj->desc();`
- Traduzione nell'alfabeto 'protein'
`$translation1 = $seqobj->translate;`
- Parametri aggiuntivi:
 - frame della traduzione (0, 1 o 2)
`$translation2 = $seqobj->translate(
 undef, undef, 1);`
 - codon table da usare (sono 16)
`$human_mitochondrial_translation =
 $seqobj->translate(
 undef, undef, undef, 2);`
 - Full coding regions (CDS)
`$protein_object = $cds->translate(
 undef, undef, undef, undef,
 1, 'die_if_errors');`

... e ancora Sequenze

- Statistiche

```
use Bio::Tools::SeqStats;  
$stats = Bio::Tools::SeqStats -> new($seqobj);  
    – Peso molecolare  
$weight = $seq_stats ->get_mol_wt();  
    – Numero di monomeri (dà la coppia min-max)  
$monomer_ref = $seq_stats -> count_monomers();  
    – Numero di codoni (per sequenze di acidi nucleici)  
$codon_ref = $seq_stats -> count_codons();
```

- Aminoacidi 'carichi'

```
use Bio::Tools::OddCodes;  
$oddcode_obj = Bio::Tools::OddCodes -> new($amino_obj);  
$output = $oddcode_obj -> charge();
```

- Descrizione chimica

```
$output = $oddcode_obj->chemical();  
    – 'ACDEFGH' diventa 'LSAARAC'  
        • A (acido), L (alifatico), M (amide), R (aromatico), C (basico),  
        H (idrossile), I (imino), S (zolfo)
```

Restriction enzyme cutting sites

- Contiene più di 500 enzimi di tipo II

```
use Bio::Restriction::EnzymeCollection;
```

```
my $all_collection = Bio::Restriction::EnzymeCollection;
```

- Come selezionare quelli lunghi 6 basi

```
my $six_cutter_collection = $all_collection -> cutters(6);
```

- Selezione di un enzima per nome

```
my $ecori_enzyme = $all_collection -> get_enzyme('EcoRI');
```

- Estrazione dei siti di taglio (dà una lista di stringhe)

```
use Bio::Restriction::Analysis;
```

```
my $analysis = Bio::Restriction::Analysis -> new(-seq => $seq);
```

```
@fragments = $analysis -> fragments($enzyme);
```

- Creazione di un nuovo restriction enzyme

Matching con Blast in remoto

- Usando Blast via rete su NCBI, (ma con tempi elevati)

```
$remote_blast = Bio::Tools::Run::RemoteBlast -> new (
    -prog => 'blastp', -data => 'ecoli', -expect => '1e-10' );
$r = $remote_blast->submit_blast("t/data/ecolitst.fa");
while (@rids = $remote_blast->each_rid ) {
    foreach $rid ( @rids ) {$rc = $remote_blast->retrieve_blast($rid);} }
```

- Esaminare i risultati con BIO::SearchIO

```
$searchio = new Bio::SearchIO (-format => 'blast', -file  => $blast_report);
$result = $searchio->next_result;
```

- Informazioni globali

```
$result->database_name;
$algorithm_type = $result->algorithm;
```

- Informazioni sulla prima corrispondenza trovata

```
$hit = $result->next_hit;
$hit_name = $hit->name ;
```

- Informazioni sulla prima HSP della corrispondenza trovata

```
$hsp = $hit->next_hsp;
$hsp_start = $hsp->query->start;
```

Matching con Blast locale

- Deve essere installato Blast
 - Deve essere definite le variabili BLASTDIR, BLASTDB
- Creo un wrapper StandAloneBlast

```
use Bio::Tools::Run::StandAloneBlast;
@params = (program => 'blastn', database => 'ecoli.nt');
$factory = Bio::Tools::Run::StandAloneBlast->new(@params);
```

- Eseguo la ricerca

```
$input = Bio::Seq->new(-id =>"test query", -seq =>"ACTAAGTGGGGG");
$blast_report = $factory->blastall($input);
```

- Esamino il report

```
while (my $hit = $blast_report->next_hit){
    while (my $hsp = $hit->next_hsp){
        print $hsp->score, " ", $hit->name, "\n";
    }
}
```

Ricerca di Geni

- Interfaccia ai dati prodotti dai programmi:
 - Genscan, Sim4, Genemark, Grail, ESTScan, MZEF, ePCR
- Lettura di un report Genscan

```
use Bio::Tools::Genscan;
$genscan = Bio::Tools::Genscan ->
    new(-file => 'result.genscan');
# $gene è un
# Bio::Tools::Prediction::Gene
# $gene->exons() torna un array di
# oggetti Bio::Tools::Prediction::Exon
while($gene = $genscan
    ->next_prediction()) {
    @exon_arr = $gene->exons();
}
$genscan->close();
```

- Lettura di un report Sim4

```
use Bio::Tools::Sim4::Results;
$sim4 = new Bio::Tools::Sim4::Result(
    -file=>'t/data/sim4.rev',
    -estisfirst =>0);
# $exonset è un
# Bio::SeqFeature::Generic con
# Bio::Tools::Sim4::Exons
# come sub-features
$exonset = $sim4->next_exonset;
@exons=$exonset->sub_SeqFeature();
# $exon è un
# Bio::SeqFeature::FeaturePair
$exon = 1;
$exonstart = $exons[$exon]->start();
$estname = $exons[$exon]->est_hit()
    ->seqname();
$sim4->close();
```

Allineamenti

- Input da:
 - bl2seq, clustalw, emboss, fasta, mase, mega, meme, metfasta, msf, nexus, pfam, phylip, prodom, psi, selex, stockholm
- 6 formati di output:
 - fasta, mase, selex, clustalw, msf/gcg, phylip (interleaved)
- Esempio di I/O e trasformazione di formato

```
use Bio::AlignIO;  
$in  = Bio::AlignIO -> new( -file => "inputfilename", -format => 'pfam');  
$out = Bio::AlignIO -> new( -file => ">outputfilename", -format => 'fasta');  
while ( my $aln = $in->next_aln() ){  
    $out->write_aln($aln);  
}
```

Patterns e coordinate

- Manipolazione di sequenze con espressioni regolari

```
use Bio::Tools::SeqPattern;
$pattern    = '(CCCCT)N{1,200}(agggg)N{1,200}(agggg)';
$pattern_obj = new Bio::Tools::SeqPattern(-SEQ => $pattern, -TYPE => 'dna');
$pattern_obj2 = $pattern_obj->revcom();
$pattern_obj->revcom(1); # torna il pattern complementare inverso esteso
```

- Conversione di coordinate

```
$input_coordinates = Bio::Location::Simple -> new(-seq_id => 'propeptide',
    -start => 1000, -end => 2000, -strand=>1 );
$output_coordinates = Bio::Location::Simple -> new(-seq_id => 'peptide',
    -start => 1100, -end => 2100, -strand=>1 );
$pair = Bio::Coordinate::Pair -> new(-in => $input_coordinates ,
    -out => $output_coordinates );
$pos = Bio::Location::Simple -> new (-start => 500, -end => 500 );
$res = $pair->map($pos);
$converted_start = $res->start;
```

bptutorial.pl

- Il BioPerl tutorial è un programma Perl!
 - Contiene 25 esempi di uso di BioPerl
 - Contiene la documentazione (estraibile con perldoc)
 - Usa alcuni files della distribuzione
- Installazione:
 - > `tar xzvf /MINICPAN/authors/id/B/BI/BIRNEY/bioperl-1.4.tar.gz`
 - > `cd bioperl-1.4`
- Come si usa (pagina di help)
 - > `perl -w bptutorial.pl`
- Esecuzione di una demo
 - > `perl -w bptutorial.pl N`
- Stampa dei metodi di un modulo (anche quelli ereditati)
 - > `perl -w bptutorial.pl 100 Bio::Seq`
- Tutorial in formato testo
 - > `perldoc bptutorial.pl`

Il seguito ...

... alla prossima puntata :-)

bptutorial.pl

- Il BioPerl tutorial è un programma Perl!
 - Contiene 25 esempi di uso di BioPerl
 - Contiene la documentazione (estraibile con perldoc)
 - Usa alcuni files della distribuzione
- Installazione:
 - > `tar xzvf /MINICPAN/authors/id/B/BI/BIRNEY/bioperl-1.4.tar.gz`
 - > `cd /bioperl-1.4`
- Come si usa (pagina di help)
 - > `perl -w bptutorial.pl`
- Esecuzione di una demo
 - > `perl -w bptutorial.pl N`
- Stampa dei metodi di un modulo (anche quelli ereditati)
 - > `perl -w bptutorial.pl 100 Bio::Seq`
- Tutorial in formato testo
 - > `perldoc bptutorial.pl`

Accidenti ai proxy! :-)

- Per configurare BioPerl per attraversare il proxy scrivete:
`> export http_proxy='http://10.0.0.100:3128'`
- A questo punto potete provare i tutorial 11 e 22
 - Esempio di accesso a database NCBI
`> perl bptutorial.pl 11`
 - Esempio di accesso a BLAST remoto
`> perl bptutorial.pl 22`
- Gli ultimi 3 tutorial necessitano di programmi esterni:
 - blast
 - clustalw e tcoffee
 - psw e bl2seq

Sequence Annotations

- Una annotazione è associata ad una posizione e contiene:

\$feat->start	# inizio
\$feat->end	# fine
\$feat->strand	# 1 vuol dire 'in avanti', -1 'indietro', 0 non rilevante
\$feat->primary_tag	# 'nome' della feature, ad esempio 'exon'
\$feat->source_tag	# sorgente della feature, ad esempio 'BLAST'

# metodi che tornano un oggetto Bio::PrimarySeq	
\$feat->seq	# la sequenza compresa tra 'start' ed 'end'
\$feat->entire_seq	# la sequenza intera
\$feat->spliced_seq	# la sequenza "unita", quando ci sono posizioni multiple

\$feat->overlap(\$other)	# le due feature \$feat e \$other si sovrappongono?
\$feat->contains(\$other)	# la feature \$other è completamente dentro a \$feat?
\$feat->equals(\$other)	# \$feat e \$other sono esattamente uguali?
\$feat->sub_SeqFeatures	# crea/legge un array di feature di sottosequenze

- Annotazioni dettagliate (RichSeq) ricavate da DB

```
@secondary = $richseq->get_secondary_acccessions;  
$division = $richseq->division;  
@dates = $richseq->get_dates;  
$seq_version = $richseq->seq_version;
```

Sequenze enormi (LargeSeq)

- Permettono di manipolare sequenze enormi (>100 Mbasi)

```
$seqio = new Bio::SeqIO( -format => 'largefasta',
                        -file    => 't/data/genomic-seq.fasta');
$pseq      = $seqio->next_seq();
$plength   = $pseq->length();
$last_4    = $pseq->subseq($plength-3,$plength); # questo è OK!!!
```

- Si possono usare tutti i metodi di una Seq **tranne** quelli che tornano come risultato **tutta la sequenza**

```
# questo invece dà quasi sicuramente un errore di allocazione di memoria!!!
# $lots_of_data = $pseq->seq(); # NON OK per una LargeSeq
```

Sequenze che cambiano (LiveSeq)

- Con le LiveSeq è possibile manipolare sequenze i cui dati vengono aggiornati frequentemente
 - Le posizioni non sono implementate come numeri costanti ma calcolate solo al momento in cui servono
-

```
$loader = Bio::LiveSeq::IO::BioPerl->load(  
    -db      => "EMBL",  
    -file    => "t/data/factor7.embl");  
$gene  = $loader->gene2liveseq(-gene_name => "factor7");  
$id    = $gene->get_DNA->display_id ;  
$maxstart = $gene->maxtranscript->start;
```

Mutazioni e Polimorfismi (Allele, SeqDiff)

- Mutazioni:
 - Un oggetto 'Mutation' descrive una modifica da applicare ad una sequenza di DNA di un gene
 - Un oggetto 'Mutator' applica le mutazioni ad un gene di una LiveSeq
 - Il risultato è una lista di 'Variation' che descrivono le modifiche avvenute
- SeqDiff permette di trovare e stampare le differenze tra due geni

```
use Bio::LiveSeq::IO::BioPerl;
use Bio::LiveSeq::Mutator;
use Bio::LiveSeq::Mutation;
$loader      = Bio::LiveSeq::IO::BioPerl->load(      -file => "$filename");
$gene        = $loader->gene2liveseq(                -gene_name => $gene_name);
$mutation    = new Bio::LiveSeq::Mutation (           -seq =>'G', -pos => 100 );
$mutate      = Bio::LiveSeq::Mutator->new(          -gene => $gene,
                                                    -numbering => "coding" );
$mutate->add_Mutation($mutation);
$seqdiff = $mutate->change_gene();
$DNA_re_changes = $seqdiff->DNAMutation->restriction_changes;
$RNA_re_changes = $seqdiff->RNAChange->restriction_changes;
if (! $DNA_re_changes eq $RNA_re_changes) {
    print "Different!\n"
};
```

Clusters di sequenze (Cluster, ClusterIO)

- Manipolazione di insiemi di sequenze
 - E' previsto l'I/O solo in formato **Unigene**
- Esempio: estrarre le sequenza da un cluster e stamparne gli accession numbers

```
my $stream = Bio::ClusterIO->new(-file => "Hs.data", -format => "unigene");
while ( my $in = $stream->next_cluster ) {
    print $in->unigene_id() . "\n";
    while ( my $sequence = $in->next_seq ) {
        print $sequence->accession_number . "\n";
    }
}
```

Strutture 3D e files PDB (StructureIO)

- Operazioni sui dati di strutture 3D

- Leggo un file PDB

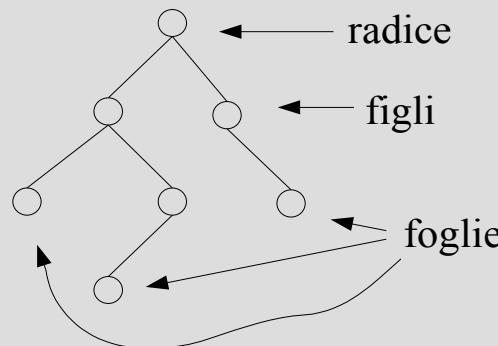
```
$structio      = Bio::Structure::IO->new( -file => "1XYZ.pdb");
$struc        = $structio->next_structure;      # torna un oggetto Entry
$pseq         = $struc->seqres;                  # torna una PrimarySeq
$pseq->subseq(1,20);                            # torna una stringa
```

- Estrazione delle coordinate degli atomi di un Residuo

```
# dato un Residue, torna una lista di oggetti Atom
@atoms        = $struc->get_atoms($res);
@xyz          = $atom->xyz;                      # le coordinate 3D dell'atomo
```

Alberi e alberi filogenetici (TreeIO, PAML)

- Potete manipolare alberi generici con la classe Tree
 - Gli alberi in informatica hanno la radice in alto e le foglie in basso :-)
 - I discendenti (figli) di un nodo sono i nodi immediatamente sotto
 - Le foglie sono nodi che non hanno nessun discendente (figli)



- Con TreeIO potete leggere/scrivere nei formati **phylip** o **newick**

```
$treeio = new Bio::TreeIO( -format => 'newick', -file => $treefile);
$tree      = $treeio->next_tree;          # legge un albero dal file
@nodes    = $tree->get_nodes;           # torna tutti i nodi
# ottiene tutti i discendenti del nodo radice
$tree->get_root_node->each_Descendent;
```
- Con PAML leggete l'output dei programmi:
 - **codeml**, **baseml**, **basemlg**, **codemlsites** e **yn00**

Programmi esterni: EMBOSS

- Installando bioperl-ext potete usare da Perl i programmi EMBOSS

- Esempio:

```
$factory = new Bio::Factory::EMBOSS;  
$compseqapp = $factory->program('compseq');  
%input = ( -word      => 4,  
          -sequence   => $seqObj,  
          -outfile    => $compseqoutfile );  
$compseqapp->run(\%input);  
$seqio = Bio::SeqIO->new( -file => $compseqoutfile ); # etc...
```

- Si possono usare anche nomi di file per l'input e l'output:

```
-sequence => "inputfasta.fa"
```

Programmi esterni: Pise

- Se non avete EMBOSS installato potete usare i programma installati sul server Pise (Pasteur Institute)

```
my $genscan = Pise::genscan->new(
    "http://bioweb.pasteur.fr/cgi-bin/seqanal/genscan.pl"
    'letondal@pasteur.fr',
    seq => $seq,
    parameter_file => "Arabidopsis.smat");
my $job = $genscan->run;
my $parser = Bio::Tools::Genscan->new(-fh => $job->fh('genscan.out') );
while(my $gene = $parser->next_prediction()) {
    my $prot = $gene->predicted_protein;
    print $prot->seq, "\n";
}
```

Allineare due sequenze con bl2seq e AlignIO

- Potete usare bl2seq e AlignIO per allineare due sequenze usando blast in locale
 - Create un lanciatore di blast in locale

```
$factory = Bio::Tools::Run::StandAloneBlast->new('outfile' => 'bl2seq.out');
```
 - Eseguite bl2seq e ne ricavate il report

```
$bl2seq_report = $factory->bl2seq($seq1, $seq2);
```
 - Usate AlignIO per creare un oggetto SimpleAlign dai dati del report

```
$str = Bio::AlignIO->new(  
    -file  => 'bl2seq.out',  
    -format => 'bl2seq');
```

```
$aln = $str->next_aln();
```

Allineare sequenze multiple

- Per allineare sequenze multiple si possono usare **clustalw** o **tcoffee**
 - Devono essere installati nel sistema
 - Vanno settate le due variabili **CLUSTALDIR** e **TCOFFEEDIR**

- Esempio

```
use Bio::Tools::Run::Alignment::Clustalw;
@params = ('ktuple' => 2, 'matrix' => 'BLOSUM');
$factory = Bio::Tools::Run::Alignment::Clustalw->new(@params);
$ktuple = 3;
$factory->ktuple($ktuple);
$seq_array_ref = \@seq_array;
    # dove @seq_array è un vettore di oggetti Bio::Seq
$aln = $factory->align($seq_array_ref);
```

Allineamenti con Smith-Waterman

- Allineamenti col metodo Smith-Waterman
 - Deve essere installato **bioperl-ext**
 - Deve essere installato il programma **pSW**
 - **Solo per proteine**
 - Sono presenti le matrici **blosum62** e **gonnet250**
 - Se ne possono aggiungere altre
- Esempio

```
use Bio::Tools::pSW;
$factory = new Bio::Tools::pSW( '-matrix' => 'blosum62.bla',
                             '-gap' => 12,
                             '-ext' => 2, );
$factory->align_and_show($seq1, $seq2, STDOUT);
$aln = $factory->pairwise_alignment($seq1, $seq2);
```