

Docente: **Matteo Re**

UNIVERSITÀ DEGLI  
STUDI DI MILANO



C.d.l. Biotecnologie Industriali e Ambientali

# Biologia

A.A. 2012-2013 semestre I

# computazionale

**p1**

**Introduzione**

- **Programmazione PERL**
  - Soluzione problemi e Debugging
  - Manipolazione dei dati: filtro e trasformazione
  - Pattern matching e data mining (esempi)
  - Utilizzo di argomenti
  - Lettura di file

# **Obiettivi**

---



# Linee guida

- **Sistema operativo**

- In aula di calcolo utilizzeremo windows

- **Installazione PERL**

**WIN:**

<http://www.activestate.com/activeperl/downloads>

**UNIX, MacOS:**

normalmente già disponibile

- **Editor di testo**

- I programmi PERL vengono salvati come file di testo. Ci sono molte opzioni disponibili:

- <http://www.vim.org> (UNIX like OS)
- Notepad++ (Windows)

- Se siete interessati ad un **IDE**, questi sono adatti al lavoro che svolgeremo e sono free:

- [www.eclipse.org](http://www.eclipse.org)
- [www.activestate.com/komodo-ide](http://www.activestate.com/komodo-ide)

# File sequenze – Formato **FASTA**

>gi|40457238| HIV-1 isolate 97KE128 from Kenya gag gene, partial cds  
CTTTGAATGCATGGTAAAAGTAATAGAAGAAAGAGGTTCAGTCCAGAAGTAATACCCATGTTCTCAG  
CATTATCAGAAGGAGCCACCCCACAAGATTAAATACGATGCTGAACATAGTGGGGGACACCAGGCAGC  
TATGCAAATGCTAAAGGATACCATCAATGAGGAAGCTGCAGAATGGGACAGGTTACATCCAGTACATGCA  
GGGCCTATTCCGCCAGGCCAGATGAGAGAACCAAGGGGAAGTGACATAGCAGGAACACTACTAGTACCCCTC  
AAGAACAAAGTAGGATGGATGACAAACAATCCACCTATCCCAGTGGGAGACATCTATAAAAGATGGATCAT  
CCTGGGCTTAAATAAAATAGTAAGAATGTATAGCCCTGTTAGCATTGGACATAAAACAAGGGCCAAAA  
GAACCCCTTAGAGACTATGTAGATAGGTTCTTAAACTCTCAGAGCCGAACAAGCTT

>gi|40457236| HIV-1 isolate 97KE127 from Kenya gag gene, partial cds  
TTGAATGCATGGTAAAAGTAATAGAAGAAAAGGCTTCAGCCCAGAAGTAATACCCATGTTCTCAGCAT  
TATCAGAAGGAGCCACCCCACAAGATTAAATATGATGCTGAATATAGTGGGGGACACCAGGCAGCTAT  
GCAAATGTTAAAGATACCATCAATGAGGAAGCTGCAGAATGGGACAGGTTACATCCAATACATGCAGGG  
CCTATTCCACCAGGCCAAATGAGAGAACCAAGGGGAAGTGACATAGCAGGAACACTACTAGTACCCCTCAAG  
AGCAAATAGGATGGATGACAAGCAACCCACCTATCCCAGTGGGAGACATCTATAAAAGATGGATAATCCT  
GGGATTAATAAAATAGTAAGAATGTATAGCCCTGTTAGCATTGGACATAAAACAAGGGCCAAAAGAA  
CCTTCAGAGACTATGTAGATAGGTTTTAAACTCTCAGAGCCGAACAAGCTT

>gi|40457234| HIV-1 isolate 97KE126 from Kenya gag gene, partial cds  
CCTTTGAATGCATGGTAAAAGTAATAGAAGAAAAGGCTTCAGCCCAGAAGTAATACCCATGTTTCAG  
CATTATCAGAAGGAGCCACCCCACAAGATTAAATATGATGCTGAACATAGTGGGGGGCACCAGGCAGC  
TATGCAAATGTTAAAGATACCATCAATGAGGAAGCTGCAGAATGGGACAGGCTACATCCAGCACAGGCA  
GGGCCTATTGCACCAGGCCAGATAAGAGAACCAAGGGGAAGTGATATAGCAGGAACACTACTAGTACCCCTC  
AAGAACAAATAGCATGGATGACAGGCAACCCGCCTATCCCAGTGGGAGACATCTATAAAAGATGGATAAT  
CCTGGGATTAAATAAAATAGTAAGAATGTATAGCCCTGTTAGCATTGGATATAAAACAAGGGCCAAAA  
GAACCATTAGAGACTATGTAGACAGGTTCTTAAACTCTCAGAGCCGAACAAGCTT

# GenBank Record

LOCUS AK091721 2234 bp mRNA linear PRI 20-JAN-2006  
DEFINITION Homo sapiens cDNA FLJ34402 fis, clone HCHON2001505.  
ACCESSION AK091721  
VERSION AK091721.1 GI:21750158  
KEYWORDS oligo capping; fis (full insert sequence).  
SOURCE Homo sapiens (human)  
ORGANISM Homo sapiens  
Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Euteleostomi;  
Mammalia; Eutheria; Euarchontoglires; Primates; Catarrhini;  
Hominidae; Homo.  
TITLE Complete sequencing and characterization of 21,243 full-length  
human cDNAs  
JOURNAL Nat. Genet. 36 (1), 40-45 (2004)  
FEATURES Location/Qualifiers  
source 1..2234  
/organism="Homo sapiens"  
/mol\_type="mRNA"  
CDS 529..1995  
/note="unnamed protein product"  
/codon\_start=1  
/protein\_id="BAC03731.1"  
/db\_xref="GI:21750159"  
/translation="MVAERSPARSPGSWLFPGWLVLSGPGGLLRAQEQPSCRRAFD  
...  
RLDALWALLRRQYDRVSLMRPQEGDEGRCINFSRVPSQ"  
ORIGIN  
1 gtttcggag tgccggaggga gttggggccg ccggaggaga agagtctcca ctcctagtt  
61 gttctgccgt cgccgcgtcc cagggacccc ttgtccccaa gcgcacggca gcggggggaa  
...

# Perchè Perl?

- **Ampiamente utilizzato in biologia computazionale**
  - Bioperl
    - [http://www.bioperl.org/wiki/Main\\_Page](http://www.bioperl.org/wiki/Main_Page)
- **Relativamente semplice da programmare**
  - Ottimo per problemi di pattern matching
  - Semplice creazione di pipelines (controllo di altri programmi)
  - Facile da apprendere (relativamente)
- **Rapida prototipizzazione**
  - Molti problemi possono essere risolti con poche righe di codice
- **Portabilità**
  - Disponibile su *Unix, Windows, Mac*
- **Mentalità Open source radicata da tempo**
  - Molte fonti di informazioni ( provare: %perldoc perldoc)
    - %perldoc -f print
  - <http://perldoc.perl.org/index-tutorials.html>
  - Molti moduli disponibili (<http://www.cpan.org/>)

## L'interprete perl

PERL è un linguaggio interpretato.



L'interprete PERL si occupa di **tradurre** una istruzione scritta in un linguaggio comprensibile per un essere umano in una corrispondente istruzione scritta in un linguaggio comprensibile ad un calcolatore.

Esegue l'istruzione appena tradotta

Continua fino a quando non rimane nessuna istruzione da tradurre

Esiste comunque la possibilità di compilare il codice in un unico file costituito interamente da istruzioni comprensibili al calcolatore generando un **eseguibile** (maggiore velocità di esecuzione).

---

Docente: **Matteo Re**

UNIVERSITÀ DEGLI  
STUDI DI MILANO



C.d.l. Biotecnologie Industriali e Ambientali

# Biologia

A.A. 2012-2013 semestre I

# computazionale

**p2**

**BASI DI PERL**

I tipi di variabile PERL sono indicati dall **simbolo iniziale** presente nel loro nome:

**\$var** contiene uno scalare (singola stringa o numero)

```
$x = 10;  
$s = "ATTGCGT";  
$x = 3.1417;
```

**@var** contiene un array (lista di valori)

```
@a = (10, 20, 30);  
@a = (100, $x, "Jones", $s);  
print "@a\n"; # prints "100 3.1417 Jones ATTGCGT"
```

**%var** contiene un hash (array associativo)

```
%ages = { John => 30, Mary => 22, Lakshmi => 27 } ;  
print $age{"Mary"}, "\n"; # prints 22
```

# Variabili

---

**use strict;**

- Inserire **use strict** all'inizio di un sorgente PERL fa sì che quest'ultimo vi "punisca" con un'interruzione di esecuzione quando infrangete certe regole.
- Vi obbliga a dichiarare tutte le variabili
- Evita che le variabili vengano create per errori di battitura
- Le variabili si possono dichiarare usando **my**, **our** o **local**
- Per ora usiamo solo **my**:

```
my $a;                      # value of $a is undef
my ($a, $b, $c); # $a, $b, $c are all undef
my @array;                  # value of @array is ()
```

- E' possibile combinare dichiarazione ed inizializzazione:

```
my @array = qw/A list of words/;
my $a = "A string";
```

# Dichiarazione di variabili

---

- Tutte le operazioni in PERL sono valutate in **contesto lista o scalare**. Comportamento differente a seconda del contesto.

```
@array = ('one', 'two', 'three');  
$a = @array;      # scalar context for assignment, return size  
print $a;         # prints 3  
  
($a) = @array;           # list context for assignment  
print $a;               # prints 'one'  
  
($a, $b) = @array;  
print "$a, $b";          # prints 'one, two'  
($a, $b, $c, $d) = @array;    # $d is undefined
```

# Contesto lista e scalare

---

- Concatenamento di stringhe

```
$DNA1 = "ATG" ;
$DNA2 = "CCC" ;
$DNA3 = $DNA1 . $DNA2;          # concatenation operator
$DNA3 = "$DNA1$DNA2";          # string interpolation
print "$DNA3";                  # prints ATGCC

$DNA3 = '$DNA1$DNA2';          # no string interpolation
print "$DNA3";                  # prints $DNA1$DNA2
```

# Operazioni su stringhe

---

# Arrays

Un array contiene una lista ordinata di scalari:

```
@gene_array = ('EGF1', 'TFEC', 'CFTR', 'LOC1691');  
print "@gene_array\n";
```

Output:

```
EGF1 TFEC CFTR LOC1691
```

```
# there's more than one way to do it (see previous slide  
# on declaring variables)  
@gene_array = qw/EGF1 TFEC CFTR LOC1691/;
```

The 'quote word' function `qw()` is used to generate a list of words. It takes a string such as:

```
tempfile tempdir
```

and returns a quoted list:

```
'tempfile', 'tempdir'
```

**Un array contiene una lista ORDINATA di scalari:**

```
@a = ('one', 'two', 'three', 'four');
```

**Ad ogni elemento dell'array è associato un indice. Gli indici partono da 0:**

```
print "$a[1] $a[0] $a[3]\n";
```

**stampa:**

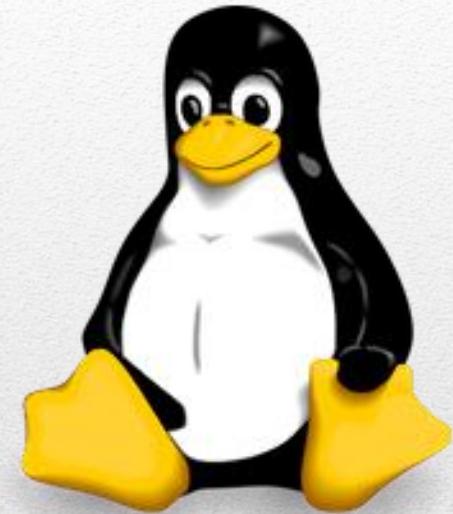
```
two one four
```

**Nota bene: `$a[i]` è uno scalare poichè abbiamo utilizzato il contesto `$` per riferirci alla variabile.**

# Arrays

---

**Diverse modalità a seconda del sistema operativo:** il punto cruciale è come far capire al sistema che vogliamo invocare l'interprete PERL per eseguire lo script.



	MAC	WIN	*NIX
Prima riga esecuzione	<code>#!/usr/bin/perl</code>		<code>#!/usr/bin/perl</code>
	<code>./nomescript (*)</code>	<code>perl nomescript</code>	<code>./nomescript (*)</code>

# Eseguire script PERL

Sistemi UNIX, MAC : nella  
shell scrivere **whereis perl**

```
#!/usr/bin/perl -w
# Example 1 Storing DNA in a variable, and printing it out

# First we store the DNA in a variable called $DNA
$DNA = 'ACGGGAGGACGGGAAAATTACTACGGCATTAGC';

# Next, we print the DNA onto the screen
print $DNA;

# Finally, we'll specifically tell the program to exit
exit;

-- Changing permissions
% chmod +x example1.pl

-- Running a perl script
% ./example1.pl      (UNIX,MAC)
> perl example1.pl  (WIN)
```

Sistemi UNIX, MAC :  
rendere **eseguibile** lo script

# Eseguire script PERL

# Lavorare in PERL

1. Creare una **directory**
2. Aprire una **shell** (\*NIX, MAC) o il **prompt** dei comandi (WIN) e posizionarsi **nella directory** appena creata (comando **cd**)
3. Aprire un **editor** (Notepad (WIN), VIM, KOMOD, ECLIPSE ...)
4. Scrivere un programma in PERL
5. **Salvare il file nella directory** appena creata
6. Tornare alla finestra della **shell** (o al **prompt** dei comandi)
7. **Eseguire** lo script perl

Se ci sono errori, tornare all'editor, modificare lo script, **salvare**, tornare al prompt/shell e rieseguire lo script.

---

- Operatori di Match
- Sostituzione
- Transliterazione
- Funzioni per stringhe
  - length, reverse
- Funzioni per arrays
  - scalar, reverse, sort
  - push, pop, shift, unshift
- Cicli
  - while, foreach, for
- Split e join
- Input/Output

# Argomenti

---

```
$dna = "ATGCATTT";
if ($dna =~ /ATT/) {
    print "$dna contains ATT\n";
}
else {
    print "$dna doesn't contain ATT\n";
}
```

= ~

*Output:*

```
ATGCATTT contains ATT
# matching a pattern
$dna = "ATGAAATTT";
$pattern = "GGG";
if ($dna =~ /$pattern/) {
    print "$dna contains $pattern\n";
}
else {
    print "$dna doesn't contain $pattern\n";
}
print "\n";
```

ATGAAATTT doesn't contain GGG

# Operatore Match

```
print "substitution example:\n";
$dna = "ATGCATTT";
print "Old DNA: $dna\n";
$dna =~ s/TGC/gggagc/;
print "New DNA: $dna\n\n";
```

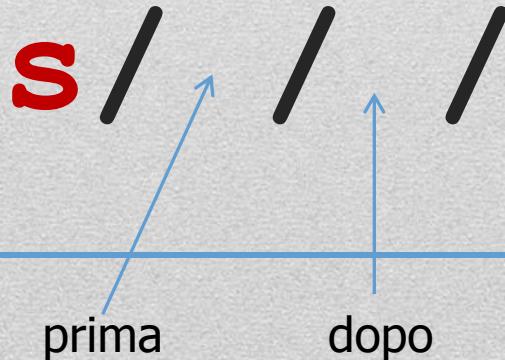
**substitution example:**  
**Old DNA: ATGCATTT**  
**New DNA: AgggagcATT**

```
print "single substitution:\n";
$dna = "ATGCATTT";
print "Old DNA: $dna\n";
$dna =~ s/T/t/;
print "New DNA: $dna\n\n";
```

**single substitution:**  
**Old DNA: ATGCATTT**  
**New DNA: AtGCATTT**

```
print "global substitution:\n";
$dna = "ATGCATTT";
print "Old DNA: $dna\n";
$dna =~ s/T/t/g;
print "New DNA: $dna\n\n";
```

**global substitution:**  
**Old DNA: ATGCATTT**  
**New DNA: AtGCAtt**



# Sostituzione

```
print "removing white space\n";
$dna = "ATG CATT CGCATAG";
print "Old DNA: $dna\n";
$dna =~ s/\s//g;
print "New DNA: $dna\n\n";
```

removing white space  
Old DNA: ATG CATT CGCATAG  
New DNA: ATGCATTCGCATAG

```
print "substitution ignoring
case\n";
$dna = "ATGCAttT";
print "Old DNA: $dna\n";
$dna =~ s/T/U/gi;
print "New DNA: $dna\n\n";
```

substitution ignoring case  
Old DNA: ATGCAttT  
New DNA: AUGCAUUU

# Sostituzione

# Calcolo della strand complementare di DNA (con baco)

```
#!/usr/bin/perl -w
# Calculating the complement of a strand of DNA (with bug)

# The DNA
$strand1 = 'ACGGGAGGACGGAAAATTACTACGGCATTAGC';
print "strand1: $strand1 \n";

# Copy strand1 into strand2
$strand2 = $strand1;

# Replace all bases by their complements: A->T, T->A, G->C, C->G
$strand2 =~ s/A/T/g;
$strand2 =~ s/T/A/g;
$strand2 =~ s/G/C/g;
$strand2 =~ s/C/G/g;

print "strand2: $strand2 \n";
exit;

% complement1
strand1: ACGGGAGGACGGAAAATTACTACGGCATTAGC
strand2: AGGGGAGGAGGGGAAAAAAAGAAGGGGAAAGG
```



Sapete trovare il baco?

```
print "transliteration operator\n";
$dna = "ATGCAttT";
print "Old DNA: $dna\n";
$dna =~ tr/T/U/;
print "New DNA: $dna\n\n";
```

transliteration operator  
Old DNA: ATGCAttT  
New DNA: AUGCAttU

```
print "tr on multiple
      characters\n";
$dna = "ATGCAttT";
print "Old DNA: $dna\n";
$dna =~ tr/Tt/Uu/;
print "New DNA: $dna\n\n";
```

tr on multiple characters  
Old DNA: ATGCAttT  
New DNA: AUGCAuuU

tr / / /

# Operatore di Transliterazione

```
print "DNA complement strand\n";
$dna = "ATGCAttT";
$complement = $dna;
$complement =~ tr/AaTtGgCc/TtAaCcGg/ ;
print "$dna\n";
print "$complement\n\n";
```

DNA complement strand  
ATGCAttT  
TACGTaaA

# Strand Complementare di DNA

# Calcolo della strand complementare di DNA (senza baco)

```
#!/usr/bin/perl -w
# Calculating the complement of a strand of DNA

# The DNA
$strand1 = 'ACGGGAGGACGGAAAATTACTACGGCATTAGC';
print "strand1: $strand1\n";

# Copy strand1 into strand2
$strand2 = $strand1;

# Replace all bases by their complements: A->T, T->A, G->C, C->G
# tr replaces each char in first part with char in second part
$strand2 =~ tr/ATGC/TACG/;

print "strand2: $strand2 \n";
exit;

% complement2
strand1: ACGGGAGGACGGAAAATTACTACGGCATTAGC
strand2: TGCCCTCCTGCCCTTTAATGATGCCGTAATCG
```

Come è stato eliminato il baco?

```
print "length function\n";
$dna = "ATGCAttT";
$size = length($dna);
print "DNA $dna has length $size\n\n";
```

length function  
DNA ATGCAttT has length 8

# Funzione Length

---

```
print "reverse function\n";
$dna = "ATGCAttT";
$reverse_dna = reverse($dna);
print "DNA: $dna\n";
print "Reverse DNA:
$reverse_dna\n\n";
```

reverse function

DNA: ATGCAttT

Reverse DNA: TttACGTA

```
print "reverse complement\n";
$dna = "ATGCAttT";
$rev_comp = reverse($dna);
$rev_comp =~
tr/AaTtGgCc/TtAaCcGg/ ;
print "$dna\n";
print "$rev_comp\n\n";
```

reverse complement

ATGCAttT

AaaTGCAT

# Funzione Reverse

# Funzioni su Array : scalar, reverse, sort

```
print "array of gene names\n";
@genes = ("HOXB1", "ALPK1", "TP53");
$size = scalar @genes;
print "A list of $size genes: @genes\n";
@genes = reverse @genes;
print "Reversed list of $size genes: @genes\n";
@genes = sort @genes;
print "Sorted list of $size genes: @genes\n\n";

array of gene names
A list of 3 genes: HOXB1 ALPK1 TP53
Reversed list of 3 genes: TP53 ALPK1 HOXB1
Sorted list of 3 genes: ALPK1 HOXB1 TP53
```

# Aggiunta di elementi alla fine di un array

```
print "Appending to an array\n";
@genes = ("HOXB1", "ALPK1", "TP53");
push @genes, "ZZZ3";
$size = scalar @genes;
print "There are now $size genes: @genes\n";
push @genes, ("EGF", "EFGR");
$size = scalar @genes;
print "There are now $size genes: @genes\n\n";
```

Appending to an array

There are now 4 genes: HOXB1 ALPK1 TP53 ZZZ3

There are now 6 genes: HOXB1 ALPK1 TP53 ZZZ3 EGF EFGR

---

# Rimuovere elementi alla fine di un array

```
print "Removing items from end of array\n";
@genes = ("HOXB1", "ALPK1", "TP53", "EGF");
$size = scalar @genes;
print "A list of $size genes: @genes\n";
pop @genes;
$size = scalar @genes;
print "There are now $size genes: @genes\n";
$gene = pop @genes;
$size = scalar @genes;
print "There are now $size genes: @genes\n";
print "The gene removed was $gene\n\n";
```

```
Removing items from end of array
A list of 4 genes: HOXB1 ALPK1 TP53 EGF
There are now 3 genes: HOXB1 ALPK1 TP53
There are now 2 genes: HOXB1 ALPK1


---


There gene removed was TP53
```

# Rimuovere elementi dall' inizio di un array

```
print "Removing items from front of array\n";
@genes = ("HOXB1", "ALPK1", "TP53", "EGF");
$size = scalar @genes;
print "A list of $size genes: @genes\n";
shift @genes;
$size = scalar @genes;
print "There are now $size genes: @genes\n";
$gene = shift @genes;
$size = scalar @genes;
print "There are now $size genes: @genes\n";
print "The gene removed was $gene\n\n";
```

Removing items from front of array

A list of 4 genes: HOXB1 ALPK1 TP53 EGF

There are now 3 genes: ALPK1 TP53 EGF

There are now 2 genes: TP53 EGF

---

There gene removed was ALPK1

```
@genes = ("HOXB1", "ALPK1", "TP53");
while (scalar @genes > 0) {
    $gene = shift @genes;
    print "Processing gene $gene\n";
    # put processing code here
}
```

Processing gene HOXB1  
Processing gene ALPK1  
Processing gene TP53

```
@genes = ("HOXB1", "ALPK1", "TP53");
while (@genes) {
    $gene = shift @genes;
    print "Processing gene $gene\n";
    # put processing code here
}
$size = scalar @genes;
print "There are now $size genes in
the list: @genes\n";

Processing gene HOXB1
Processing gene ALPK1
Processing gene TP53
There are now 0 genes in the list:
```

# Ciclo while per il processamento di liste

```
print "foreach loop to process all items from a list\n";
@genes = ("HOXB1", "ALPK1", "TP53");
foreach $gene (@genes) {
    print "Processing gene $gene\n";
    # put processing code here
}
$size = scalar @genes;
print "There are still $size genes in the list: @genes\n";
```

foreach loop to process all items from a list

Processing gene HOXB1

Processing gene ALPK1

Processing gene TP53

There are still 3 genes in the list: HOXB1 ALPK1 TP53

# Ciclo foreach per il processamento di liste

```
print "another for loop to process a list\n";
@genes = ("HOXB1", "ALPK1", "TP53");
$size = scalar @genes;
for (my $i = 0; $i < $size; $i++) {
    $gene = $genes[$i];
    print "Processing gene $gene\n";
    # put processing code here
}
$size = scalar @genes;
print "There are still $size genes in the list: @genes\n";
```

another for loop to process a list

Processing gene HOXB1

Processing gene ALPK1

Processing gene TP53

There are still 3 genes in the list: HOXB1 ALPK1 TP53

# Ciclo for per il processamento di liste

```
print "converting array to
      string\n";
@genes = ("HOXB1", "ALPK1",
          "TP53");
$string = join(" ", @genes);
print "String of genes:
      $string\n";
$size = length $string;
print "String has length:
      $size\n";
```

converting array to string  
String of genes: HOXB1 ALPK1 TP53  
String has length: 16

```
print "join with empty
      separator\n";
@genes = ("HOXB1", "ALPK1",
          "TP53");
$string = join("", @genes);
print "String of genes:
      $string\n";
$size = length $string;
print "String has length:
      $size\n";
```

join with empty separator  
String of genes: HOXB1ALPK1TP53  
String has length: 14

# join : converte array in stringa

```
print "join with newline separator\n";
@genes = ("HOXB1", "ALPK1", "TP53");
$string = join "\n", @genes;
print "String of genes: $string\n";
$size = length $string;
print "String has length: $size\n\n";
```

```
join with newline separator
String of genes: HOXB1
ALPK1
TP53
String has length: 16
```

# join con separatore newline

```
print "converting string to array\n";
$dna = "ATGCATTT";
@bases = split "", $dna;
print "dna = $dna\n";
$size = scalar @bases;
print "The list of $size bases: @bases\n\n";
```

```
converting string to array
dna = ATGCATTT
The list of 8 bases: A T G C A T T T
```

**split: conversione  
di stringhe in array**

---

```
print "split on white space\n";
$string = "HOXB1 ALPK1    TP53";
@genes = split " ", $string;
print "$string\n@genes\n\n";
```

split on white space  
HOXB1 ALPK1 TP53  
HOXB1 ALPK1 TP53

```
print "split on 'P'\n";
$string = "HOXB1 ALPK1    TP53";
@genes = split "P", $string;
print "$string\n";
foreach $gene (@genes) {
    print "|$gene|\n";
}
```

split on 'P'  
HOXB1 ALPK1 TP53  
|HOXB1 AL|  
|K1 T|  
|53|

# split: utilizzo separatori

Docente: **Matteo Re**

UNIVERSITÀ DEGLI  
STUDI DI MILANO



C.d.l. Biotecnologie Industriali e Ambientali

# Biologia

A.A. 2012-2013 semestre I

# computazionale

**p3**

**Interagire con l'esterno  
(dello script)**

L'array **@ARGV** è la lista degli **argomenti** che vengono passati al programma:

**% myprogram.pl hello 73 abcdef**

è equivalente a:

```
@ARGV = ("hello", 73, "abcdef") ;
```

**@ARGV : un array speciale**

L'array **@ARGV** è la lista degli **argomenti** che vengono passati al programma. Ovviamente questa variabile è considerata speciale da perl.

Supponiamo di aver lanciato uno script così:

```
> perl myprogram.pl hello 73 abcdef
```

Se all'interno dello script scriviamo:

```
$a = shift;
```

Questi argomenti sono inseriti in **@ARGV**

l'interprete perl si trova a dover gestire una situazione particolare: **shift** serve ad **estrarre il primo elemento da un array** ... ma non gli diciamo da quale array!!!

Risultato: perl estrae il **PRIMO** argomento da **@ARGV**, ossia hello

# funzione shift

L'array **@ARGV** è la lista degli **argomenti** che vengono passati al programma. Ovviamente questa variabile è perl.

Supponiamo di aver lanciato

> perl myprog

o

\$a =

per

qua

oss

**NB:** L'ordine conta! Quando chiamiamo shift **la prima volta** estraie **il primo elemento** di @ARGV, quando usiamo shift per la seconda volta estraе sempre il primo elemento di @ARGV ma il primo elemento originale non c'è più ... quindi, in realtà estraе il **SECONDO** elemento di @ARGV.  
E così via ...

PRIMO argomento da @ARGV,  
**funzione shift**

sono inseriti

e una  
carre il  
amo da

Perl ha due modi principali di aprire I files:

- alla maniera della shell (prompt) per convenienza
- Alla maniera del linguaggio C per precisione

Apertura files: la via della shell:

```
% myprogram file1 file2 file3  
% myprogram < inputfile  
% myprogram > outputfile  
% myprogram >> outputfile  
% myprogram | otherprogram  
% otherprogram | myprogram
```

Qui entra in gioco la funzione **shift**

# Apertura files

```
#!/usr/bin/perl
use strict;
use warnings;
# File: readname.pl

# Read in name and age
print "Enter your name: ";
my $name = <>;                      # "<>" reads one line from "standard input"
chomp $name;                          # chomp deletes any newlines from end of
                                    # string

print "Enter your age: ";
my $age = <>;
chomp $age;

print "Hello, $name!  ";
print "On your next birthday, you will be ", $age+1, ".\n";
exit;
```

```
% readname.pl
Enter your name: Joe Smith
Enter your age: 20
Hello, Joe Smith! On your next birthday, you will be 21.
```

# Input interattivo da tastiera

```
% cat infile  
Joe Smith  
20
```



NBB: variabili **separate**  
**da newline**

```
% readname.pl < infile  
Enter your name: Enter your age: Hello, Joe Smith! On your  
next birthday, you will be 21.  
%
```

# Input da file

( Comodo per leggere **file parametri** )

```
#!/usr/bin/perl
use strict;
use warnings;

# Read in name and age
# print "Enter your name: ";
my $name = <>;                      # "<>" reads one line from "standard input"
                                         # chomp deletes any newlines from end of string
chomp $name;

# print "Enter your age: ";
my $age = <>;
chomp $age;

print "Hello, $name!  ";
print "On your next birthday, you will be ", $age+1, ".\n";
exit;

% readname.pl < infile
Hello, Joe Smith!  On your next birthday, you will be 21.
%
```

**Commentate ( # ) tutte le chiamate  
print PRIMA della lettura del file**

# Input da file file

( visto dall'interno dello script)

- La funzione **open** richiede **due** argomenti:
  - Un **filehandle**
  - Una **stringa** che dice a PERL **cosa** aprire e **come**.
- Open ritorna 1 quanto tutto è andato bene o mette la descrizione dell'errore nella variabile speciale **\$!** e poi blocca il programma
- Se un filehandle con lo stesso nome è già aperto **lo chiude** implicitamente

```
open INFO, "< datafile" or die "can't open datafile: $!";  
open RESULTS,> runstats" or die "can't open runstats: $!";  
open LOG, ">> logfile " or die "can't open logfile: $!";
```

<           **modalità lettura**  
>           **Modalità scrittura**  
**>>**       **Modalità append (aggiunta in coda)**

# Funzione open

- La funzione **close** richiede **un** argomento:
  - Il **filehandle** aperto in precedenza dalla funzione **open**

```
open INFO,      "<  datafile"  or die "can't open datafile: $!";  
  
# ... fare qualcosa con il file  
  
close INFO;
```

## Funzione close

- Supponiamo di lavorare in una directory contenente, oltre al nostro script, anche un file di testo di nome file1.txt . Per aprire il file e leggerlo possiamo fare così:

```
open INFO,    "<  file1.txt"  or die "can't open datafile: $!" ;  
  
while(<INFO>) {  
    print $_;  
  
}  
close INFO;
```

# Lettura di file riga per riga

- Nell'esempio precedente abbiamo semplicemente letto tutte le righe di testo di un file e le abbiamo stampate. Ora vogliamo stampare solo le righe per cui è **vera una certa condizione**.

```

open INFO,    "<  file1.txt"  or die "can't open datafile: $!";
while(<INFO>) {
    $rigacorrente = @_;
    @valori=split(/\s+/, $rigacorrente);
    if($valori[2] eq "RNA") {
        print $_;
    }
}
close INFO;

```

NOTARE IL BLOCCO IF

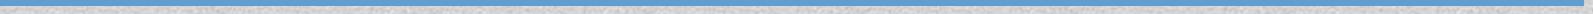
# Lettura di file filtro righe

# Esercizi ( basi di Perl ) |

- Dal sito web del corso scaricate I file **mm9\_chr1.gtf**. Il file contiene le annotazioni del genoma di topo (versione mm9) relative al cromosoma 1. La terza colonna contiene il tipo di elemento genomico a cui si riferisce l'annotazione e può contenere valri come exon, CDS, start\_codon. Scrivere uno script Perl che legga il file e che stampi sullo schermo solo le righe degli elementi di tipo exon.
- Utilizzate come base lo script dell'esercizio precedente. Dopo aver stampato tutte le righe di tipo CDS stampate anche il numero di righe di tipo exon, di tipo CDS e di tipo start\_codon.
- Scrivete uno script Perl che stampi solo le righe del gene a cui è associato il trascritto NM\_026241 .

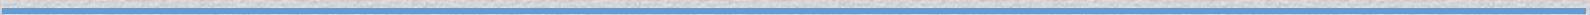
# Esercizi ( basi di Perl ) II

- Scrivete uno script Perl che stampi solo le righe del gene a cui è associato il trascritto NM\_026241 e che, inoltre, stampi il numero di esoni del trascritto.
- Lo script dell'esercizio precedente è utile ma, purtroppo, calcola il numero di esoni solo per uno specifico trascritto (NM\_026241). Riuscite a scrivere uno script che utilizzi la funzione shift per permettervi di passare il nome del trascritto a cui siete interessati come argomento al momento dell'esecuzione dello script? Lo script potrebbe essere eseguito in questo modo:  
**perl nomevostroscript.pl NM\_033570**



# Esercizi ( basi di Perl )

- Scaricate dal sito del corso il file **genes.expr**. Questo file ha 6 colonne. La prima contiene il codice associato ad ogni gene e l'ultima un valore di espressione per il gene. Scrivete uno script Perl che stampi solo le righe dei 2 geni con valore di espressione minimo e massimo. Su che cromosoma sono ?



# Perl.com

( <http://www.perl.com> )

# Perl.it

( <http://www.perl.it> )



## **Buone fonti di informazioni**

( manuali, tutorials, discussioni, recensioni ...)