

TOOLBOX DE BIOINFORMATICA: ENTORNO DE SOFTWARE INTEGRADO PARA EL GENOMA Y ANÁLISIS PROTEÓMICO

JAIRO PERTUZ CAMPO

Físico, Instructor y asesor de MATLAB, E.MAILS: jpertuz@udem.edu.co, pertuzjairo@yahoo.es

SOLON PINO G.

D. SOFTWARE PARA INGENIERIA
COMPONENTES ELECTRONICAS LTDA

1. PRESENTACIÓN DEL BIOINFORMATICS TOOLBOX

Componentes Electrónicas Ltda Distribuidor Autorizado en Colombia de **The MathWorks Inc.** anunció el 6 de Noviembre la disponibilidad de su **nuevo Bioinformatics Toolbox** para MATLAB ®. El producto facilita el análisis de datos complejos de bioinformática, de las sucesiones de análisis genómico de datos en micro-arreglos, y velocidades de desarrollo y despliegue de algoritmos. Como el Toolbox se construye en MATLAB ®, los especialistas en bioinformática pueden confiar en un análisis de datos probado y un ambiente de desarrollo de algoritmos que les permiten responder eficiente y rápidamente, con menos tareas de codificación.

"MATLAB ® proporciona una abundancia de herramientas que son críticas al planear el desarrollo de un algoritmo. El Bioinformatics Toolbox se suma naturalmente a MATLAB ® manteniendo una interface sin limitaciones y accediendo con él a los almacenes de datos del genoma esenciales y de dominio público, y proporcionando los constructores de bloques necesarios para procesar los datos "genómicos" dijo Bahram Ghaffarzadeh Kermani, Ph. D., del personal científico de Illumina, Inc. en San Diego.

El Bioinformatics Toolbox se diseña para ayudar a los usuarios a entender y visualiza cantidades grandes de datos de la investigación asociada con las aplicaciones de la tecnología biológica o biotecnología tradicionales, en un fragmento del tiempo. Con este último Toolbox The MathWorks está entregando el poder y versatilidad de su ambiente informático técnico integrado directamente a la bio-tecnología y las industrias farmacéuticas. Aprovechando la funcionalidad y riqueza de la programación en MATLAB ®, el Bioinformatics Toolbox proporciona un ambiente abierto, extensible a científicos y a bioinformáticos para el desarrollo de algoritmos, manipulación de este tipo de datos y habilita la comunicación fácil de aplicaciones por las diferentes secciones de la investigación. Como resultado, los bioinformaticos pueden usar el toolbox para enfocar los esfuerzos en el centro de su trabajo - la investigación y análisis - sin los riesgos asociados con usar programas o software dispares.

Entre sus numerosos rasgos y capacidades, el Bioinformatics Toolbox proporciona el acceso a archivos del genoma en formatos normales, los bancos de datos basados en la web como GenBank y PIR, y las fuentes de los datos en línea. El toolbox también ofrece las rutinas especializadas para visualizar los datos de microarray (micro-arreglos), incluso las cajas de gráfico, los gráficos I-R y los mapas espaciales de calor.

Los rasgos importantes adicionales del Bioinformatics Toolbox incluyen:

- Archivos y expresiones en formato comprensibles en genética, genómica y proteómica.
- Conversión, adaptación y estadísticas de secuencias del genoma y proteínas.
- Funciones de análisis proteómico.
- Gráficas de puntos, gráficas de grupos, gráficas de sectores y otras representaciones gráficas de datos genómicos y proteómicos.

" Los bioinformáticos han tenido que invertir mucho tiempo en matemática de programación y algoritmos de estadística en un horario corto, tradicionalmente," dijo Kristen Amuzzini, gerente del área de biotecnología, farmacéutica e industria médica de, The MathWorks. Y continua : "La combinación de los productos de MATLAB ® de hoy y el nuevo Bioinformatics Toolbox entrega las herramientas que ellos necesitan para analizar los datos grandes y como resultado da elementos que identifican los puntos donde potencialmente se necesita desarrollar un remedio rápida y eficazmente."

No dude en preguntarnos por el nuevo **Toolbox de Bioinformática**, es parte de una solución ágil y efectiva que puede representarle mucho ahorro de tiempo y dinero, en biotecnología, farmacéutica y medicina.

Si lo desea Usted puede abrir en www.mathworks.com el seminario

<http://matlab.udes.edu.co>

http://es.geocities.com/matlab_colombia/diamatlabnov3.html

<http://www.compelect.com.co/FormularioDiaMATLAB.html>

2. EJEMPLO DE ANALISIS DE SECUENCIAS DEL GENOMA HUMANO:

SEQSTATSDEMO Example of sequence statistics with MATLAB

This demonstration looks at some statistics about the DNA content of the human mitochondrial genome.

Contents

- Introduction
- Composition of the mitochondrial genome.
- Exploring the Open Reading Frames (ORFs)
- Extracting and analyzing the ND2 protein

Introduction

Mitochondria are generally the major energy production center in eukaryotes. The Genome repository at the NCBI contains more interesting information about the human mitochondrial genome.

```
web(http://www.ncbi.nlm.nih.gov/)
```

The consensus sequence of the human mitochondria genome has accession number NC_001807. The whole GenBank entry is quite large and this example only uses the nucleotide sequence, so you can use the **getgenbank** function with the 'SequenceOnly' flag to read just the sequence information into the MATLAB workspace.

```
mitochondria = getgenbank('NC_001807','SequenceOnly',true);
```

If you don't have a live web connection, you can load the data from a MAT-file using the command

```
% load mitochondria      % <== Uncomment this if no internet connection
```

The MATLAB **whos** command gives information about the size of the sequence.

```
whos mitochondria
Name                Size                Bytes  Class
mitochondria        1x16571              33142  char array
```

Grand total is 16571 elements using 33142 bytes

You will use some of the sequence statistics function in the Bioinformatics Toolbox to look at various properties of this sequence. You can look at the composition of the nucleotides with the **ntdensity** function.

```
ntdensity(mitochondria)
```

Composition of the mitochondrial genome.

This shows that the genome is A-T rich. You can get more specific information with the **basecount** function.

```
basecount(mitochondria)
ans =
A: 5113
C: 5192
G: 2180
T: 4086
```

These are on the 5'-3' strand. You can look at the reverse complement using the **seqrcomplement** function.

```
basecount(seqrcomplement(mitochondria))
ans =
A: 4086
C: 2180
G: 5192
T: 5113
```

As expected, the base counts on the reverse complement strand are complementary to the counts on the 5'-3' strand.

You can use the chart option to **basecount** to display a pie chart of the distribution of the bases.

```
figure
basecount(mitochondria,'chart','pie');
```

Now look at the dimers in the sequence and display the information in a bar chart using **dimercount**.

```
figure
dimercount(mitochondria,'chart','bar')
ans =
AA: 1594
AC: 1495
AG: 801
AT: 1223
CA: 1536
CC: 1779
CG: 439
CT: 1438
GA: 615
GC: 716
GG: 427
GT: 421
TA: 1368
TC: 1202
TG: 512
TT: 1004
```

You can look at codons using **codoncount**. The function **dimercount** simply counts all adjacent nucleotides; however **codoncount** counts the codons on a particular reading frame. With no options, the function shows the codon counts on the first reading frame.

```
codoncount(mitochondria)
AAA - 172    AAC - 157    AAG - 67     AAT - 123
ACA - 153    ACC - 163    ACG - 42     ACT - 130
AGA - 58     AGC - 90     AGG - 50     AGT - 43
ATA - 132    ATC - 103    ATG - 57     ATT - 96
CAA - 166    CAC - 167    CAG - 68     CAT - 135
CCA - 146    CCC - 215    CCG - 50     CCT - 182
CGA - 33     CGC - 60     CGG - 18     CGT - 20
CTA - 187    CTC - 126    CTG - 52     CTT - 98
GAA - 68     GAC - 62     GAG - 47     GAT - 39
GCA - 67     GGC - 87     GCG - 23     GCT - 61
GGA - 53     GGC - 61     GGG - 23     GGT - 25
GTA - 61     GTC - 49     GTG - 26     GTT - 36
TAA - 136    TAC - 127    TAG - 82     TAT - 107
TCA - 143    TCC - 126    TCG - 37     TCT - 103
TGA - 64     TGC - 35     TGG - 27     TGT - 25
TTA - 115    TTC - 113    TTG - 37     TTT - 99
```

Using a loop you can also look at all the other reading frames:

```
for frame = 1:3
    figure
    subplot(2,1,1); codoncount(mitochondria,'frame',frame,'figure',true);
    title(sprintf('Codons for frame %d',frame));
    subplot(2,1,2);
    codoncount(mitochondria,'reverse',true,'frame',frame,'figure',true);
    title(sprintf('Codons for reverse frame %d',frame));
end
```

Exploring the Open Reading Frames (ORFs)

In a nucleotide sequence an obvious thing to look for is if there are any open reading frames. The function **seqshoworfs** can be used to visualize ORFs in a sequence. Note: In the HTML tutorial only the first 7500 bases of the first reading frame are shown, however when running the demo you will be able to inspect the complete mitochondrial genome with the aid of the **Help Browser**.

```
seqshoworfs(mitochondria);
```

Frame 1

```
000001    gatcacaggtctatcacccctattaaccactcacgggagctctccatgcatttgggtattttcgtc
000065    tgggggggtgtgcacgcgatagcattgcgagacgctggagccggagcaccctatgtcgcagtatc
000129    tgtccttgattcctgcctcattctattttatcgcacctacgttcaatattacaggcgaacat
```

PONENCIA # 4

000193 acctactaaagtgtgtaattaattaatgcttgttaggacataataataacaattgaaatgctctgc
000257 acagccgctttccacacagacatcatacaaaaaatttccaccaaacccccctcccccgct
000321 tctggccacagcacttaaacacatctctgcccaccccccaaaaacaaagaaccctaaccagcc
000385 taaccagatttcaaattttatcttttaggcggtatgcacttttaacagtcccccccaactaaca
000449 cattattttccctcccactcccataactaactatctcatcaatacaacccccgcccctacc
000513 cagcacacacacaccgctgctaaccatccccgaaccaacccaacccccaaagacccccca
000577 cagtttatgtagcttacctcctcaaagcaatacactgaaaatgtttagacgggctcacatcacc
000641 ccataaacaataggtttggctcctagcctttctattagctcttagtaagattacacatgcaagc
000705 atccccgttccagtgagttcaccctctaaatcaccacgatcaaaagggacaagcatcaagcagc
000769 cagcaatgacgtcaaaacgcttagcctagccacacccccacgggaaacagcagtgattaacct
000833 tttagcaataaacgaaagttaactaagctataactaacccccagggttggtcaatttcgctgacg
000897 caccgcggtcacacgattaaccgaagtcaatagaagccggcgtaaaagagtggttttagatcacc
000961 cctcccccaataaagctaaaactcacctgagttgtaaaaaactccagttgacacaaaatagacta
001025 cgaaagtggctttaacatactgaacacacaatagctaagaccacaaactgggattagatcccc
001089 actatgcttagcctaaacctcaacagttaaatcaacaaaactgctcgcagaacactacgagc
001153 cacagcttaaaactcaaaaggacctggcggtgcttcataatccctctagaggagcctgttctgtaa
001217 tcgataaacccccgatcaacctcaccacctcttgctcagcctatataccgcatcttcagcaaac
001281 cctgatgaaggctacaagtaagcgaagtaccacgtaaaagacgttaggtcaaggtgtagccc
001345 **atgagttggcaagaatgggtcacatcttccccagaaaactacga**tagcccttatgaaact
001409 taagggtcgaaggtggatttagcagtaaaactgagagtagagtgcttagttgaacagggccctga
001473 agcgctacacaccgcccgtcaccctcctcaagtatacttcaaggacatttaactaaaacccc
001537 tacgcatttatatagaggagacaagtctgaacatggtaagtgtagctggaaagtgcacttgagc
001601 aaccagagtgtagcttaacacaaagcaccacacttacacttaggagatttcaacttaactgac
001665 cgctctgagctaaacctagccccaaacccactccaccttactaccagacaaccttagccaaacc
001729 atttacccaataaagtataggcgatagaaattgaaacctggcgcaatagatatagtagccgcaa
001793 gggaaagatgaaaaattataaccaagcataatataagcaaggactaacccctataccttctgcat
001857 aatgaaatgaactagaataactttgcaaggagagccaaagctaaagccccgaaaccagacgag
001921 ctacctaaagcagctaaaagagcaccacctctatgtagcaaaatagtggaagatttatag
001985 tagagcgcaaaaacctaccgagcctgggtgtagctgggttgccaagatagaactttagttcaac
002049 tttaaatttgcccacagaacctcctaaatcccttgtaaaatttaactgttagtccaaagaggaa
002113 cagctctttggacactaggaaaaaaccttgtagagagagtaaaaaatttaaccccatagtagg
002177 cctaaaagcagccaccaattaagaaagcgttcaagctcaacaccactacctaataaaatcccaa
002241 acatataactgaaactcctcacacccaattggaccaatctatcacctatagaagaactaatgtt
002305 agtataagtaacatgaaaacatttctcctcgcataagcctgctgagatcaaaacactgaaactg
002369 acaattaacagcccaatatactacaatcaaccaacaagtcattattaccctcactgtcaacccea
002433 cacaggtatgctcataaggaaaggttaaaaaagtaaaaggaactcggcaaaccttaccgccc
002497 tgtttaccaaaaacatcacctctagcatcacagatttagaggcaccgctgcccagtgacac
002561 **tgtttaacggccggtaccctaaccgtgcaaaagg**tagcataatcacttgctccttaaatagg
002625 acctgtatga**atggctccaogaggggttcagctgtctcttacttttaaccagtgaattgacctg**
002689 **ccogtgaagaggcgggca**tgacacagcaagacgagaagaccctatggagctttaatttataat
002753 gcaaacagtacctaacaaccccacaggtcctaaactaccaaacctgcattaaaaatttcgggtg
002817 gggcgacctcggagcagaacccaacctccgagcagtagatgctaagacttcaccagtcgaagcg
002881 aactactatactcaattgatccaataactgaccaacggaacaagttaacctagggataacagc
002945 gcaatcctattctagagtcacatcaacaatagggtttacgacctc**gatggtggatcaggacat**
003009 **ccogtgggtgacccgctattaagaggttcggttggtcaacgat**taaagtcctacgtgatctgag
003073 ttcagaccgagtaaatccaggtcgggtttctacttcaaatcctcctgtagcgaagga
003137 agagaaataaggcctacttcacaaagcgccttccccgtaaa**atgatcatctcaacttagtat**
003201 **tatacccacaccacccaagaacaggggtttgtaagatggcagagcccggtaatcgca**taaaac
003265 ttaaaactttacagtcagaggttcaattcctcttcttaacaacatacccatggccaacctccta
003329 ctctcattgtaccatttcaatcgcaatggcattcctaatgcttacggaacgaaaaattctag
003393 gctatatacaactacgcaaaggccccaacgttgtagggccctacgggtactacaaccttcgc
003457 tgacgccataaaactcttcaccaaaagagccctaaaacccgcccacatctaccatcacctctac
003521 **atccccggccgaccttagctctcaccatcgctcttctactatgaacccccctccccataccca**
003585 **accctgggtcaacctcaacctaggcctcctatttctagccacct**tagcctagccggtta
003649 ctcaatcctctgatcagggtagcactcaaaactcaaacctacgcccctgatcggcgactcga
003713 gtagcccaacaatctcatatgaagtcaccctagccatcattctactatcaacattactaataa
003777 gtggctcctttaacctctccaccttatcacaacacaagaacacctctgattactcctgcccac
003841 **atgacccttgccataaatatgatttatctccacactagcagagaccaaccgaaccccccttcgac**

PONENCIA # 4

```

003905    cttgccaaggaggagtcggaactagtctcaggcttcaacatcgaatacgcgcaggccccttcg
003969    ccctattcttcatagccgaatacacaaacattattataataaacaccctcaccactacaatctt
004033    cctaggaacaacata  tgacgcactctcccctgaactctacacaacataattttgtcaccaagacc
004097    ctacttctaacctccctgttctttatgaattcgaacagcataccctcgattccgctacgaccaac
004161    tcatacaccctcctatgaaaaaacttccctaccactcaccctagcattacttatatgatatgtctc
004225    cataccattacaatctccagcattccccctcaaacctaagaaatagtctgataaaagagtta
004289    ctttgatagag  taataataggagcttaaaccccccttatttctaggactatgagaatcgaacc
004353    atccctgagaatccaaaattctccgtgccacctatcacacccccatcctaaagtaaggctagcta
004417    aataagctatcgggcccataccctcgaaaatgttggttatacccttcccgtactaattaatcccc
004481    tggcccaaccctcatctactctaccactcttgcaggcacactcatcacagcgtaaagctcgca
004545    ctgattttttaccctgagtaggcctagaaataaacatgctagctttttattccagttcaaccaa
004609    aaaaataaacctcgttccacagaagctgccatcaagtatttctcagcaagcaaccgcatcca
004673    taatccttctaatagtctatcctcttcaacaataatactctccggacaa  tgaaccataaccaatac
004737    taccaatcaatactcatcattaataatcataatggctatagcaataaaacttaggaatagcccc
004801    tttcacttctgagtcacagaggttaccacaaggcaccctctgacatccggcctgcttcttctca
004865    catgacaaaaactagccccatctcaatcatataccaaaatctctccctcactaaacgtaagcct
004929    tctcctcactctctcaatcttatccatcatagcaggcagttgaggtggattaaaccaaaccag
004993    ctacgcaaaacttagcatactcctcaattaccacataggatgaataatagcagttctaccgt
005057    acaaccctaacataaccattcttaatttaactatttatattatcctaactactaccgcatcct
005121    actactcaacttaaacctccagcaccagcctactactatctcgacactgaaacaagctaaca
005185    tgactaacacccttaattccatccaccctcctctccctaggaggcctgccccgctaaccggct
005249    ttttgcccaaatgggcccattatcgaagaattcacaaaaaacaatagcctcatcatccccaccat
005313    catagccaccatcacctccttaacctctacttctacctagcctaatctactccacctcaatc
005377    acactactccccatctacaacagtaaaaaataaaatgacagtttgaacatacaaaaaccacc
005441    cattcctccccacactcatcgcccttaccagcctactcctacctatctcccccttttataactaat
005505    aatcttatagaaatttaggttaaatacagaccaagagccttcaaagccctcagtaagttgcaat
005569    acttaatttctgcaacagctaaggactgcaaaacccccactctgcatcaactgaacgcaaatcag
005633    ccactttaattagctaagcccttactagaccaatgggacttaaccacaaaacacttagttaa
005697    cagctaagcaccctaatcaactggcttcaactctacttctcccgccgccccgggaaaaaggcgga
005761    gaagccccggcaggtttgaagctgcttctcgaatttgcaattcaatagaaaatcacctcgga
005825    gctggtaaaaagaggcctaaccctgtcttttagatttacagtcctaatgcttcaactcagccattt
005889    tacctcacccccactgatgttcgcccagcctgactattctctacaaaccacaaagacattgga
005953    acactatacctattatccggcgcagtagctggagtcctaggcacagctctaagcctccttattc
006017    gagccgagctgggcccagccaggcaaccttctaggtaacgaccacatctacaacgttatcgtcac
006081    agcccatgcatttgtaataatcttcttcatagtaataaccatcataatcggaggcctttggcaac
006145    tgactagttcccctaataatcggtgcccccgat  atggcgcttccccgcataaacaacataagct
006209    tctgactcttaacctcctcctctcctactcctgctcgcactctgctatagtggaggccagagcag
006273    aacaggttgaacagctctaacctccttagcagggaaactactcccaccctggagcctccgtagac
006337    ctaaccatcttctccttacacctagcaggtgtctcctctatcttaggggccaatcaatttcatca
006401    caacaattatcaatataaaaacccccctgccataaaccaataacaaacgccccctcttctgctgatc
006465    cgtcctaatacacagcagtcctacttctcctatctctcccagtcctagctgctggcatcactata
006529    ctactaacagaccgcaacctcaacaccaccttcttogacccccgcccaggaggagaccctatc
006593    tataccaacacctattctgatttttgggtcaccctgaagtttatattcttatcctaccaggcctt
006657    cggataaatctcccatattgtaacttactactccggaaaaaaagaaccatttgatacataggtt
006721    atggtctgagct  atgatatcaattggcttccctagggtttatcgctg  tgagcacaccataattta
006785    cagtaggaatagacgtagacacagagcatattcacctccgctaccataatcatcgctatccc
006849    caccggcgtcaaaagtatttagctgactcgccacactccacggaagcaatagaaatgatctgct
006913    gcagtgctctgagccctaggattcatcttcttcttcccgtaggtggcctgactggcattgtat
006977    tagcaaacctcatcactagacatcgtaactacacgacacgtaactacgttgtagctcacttccacta
007041    tgtcctatcaataggagctgtatttgccatcataggaggcttcattcactgatttcccctattc
007105    tcaggctacaccctagaccaaacctacgcaaaaatccatttcaactatcatattcatcggcgtaa
007169    atctaacttttctcccacaacactttctcgccctatccggaatgccccgagcttactcggacta
007233    ccccgatgcatacaccaca  tgaaacatcctatcatctgtaggctcattcatttctctaacagca
007297    gtaataatataattttcatgatttgagaagccttcgcttcgaagcgaagaaagtcctaatagtag
007361    aagaacctccataaaacctggagtgactataggatgccccccaccctaccacacattcgaaga
007425    acccgtatacataaaaatctagacaaaaaaggaaaggaatcgaaccccccaagctgggtttcaagc
007489    caaccccatggc

```

PONENCIA # 4

If you compare this output to the genes shown on the NCBI page there seem to be slightly fewer ORFs, and hence fewer genes, than expected. Vertebrate mitochondria do not use the Standard genetic code so some codons have different meaning in mitochondrial genomes. For more information about using different genetic codes in MATLAB see the help for the function **geneticcode**.

```
help geneticcode
```

GENETICCODE returns a structure containing mappings for the genetic code.

MAP = GENETICCODE returns a structure containing mapping for the Standard genetic code.

GENETICCODE(ID) returns a structure of the mapping for alternate genetic codes, where *ID* is either the *transl_table* ID from the NCBI Genetics web page (<http://www.ncbi.nlm.nih.gov/Taxonomy/Utils/wprintgc.cgi?mode=c>) or one of the following supported names. *NAME* can be truncated to the first two characters of the name.

ID *Name*

1	Standard
2	Vertebrate Mitochondrial
3	Yeast Mitochondrial
4	Mold, Protozoan, and Coelenterate Mitochondrial and Mycoplasma/Spiroplasma
5	Invertebrate Mitochondrial
6	Ciliate, Dasycladacean and Hexamita Nuclear
9	Echinoderm Mitochondrial
10	Euplotid Nuclear
11	Bacterial and Plant Plastid
12	Alternative Yeast Nuclear
13	Ascidian Mitochondrial
14	Flatworm Mitochondrial
15	Blepharisma Nuclear
16	Chlorophycean Mitochondrial
21	Trematode Mitochondrial
22	Scenedesmus Obliquus Mitochondrial
23	Thraustochytrium Mitochondrial

Examples:

```
moldcode = geneticcode(4);
wormcode = geneticcode('Flatworm Mitochondrial');
```

See also *NT2AA*, *REVGENETICCODE*.

The 'GeneticCode' option to the **seqshoworfs** function allows you to look at the ORFs again but this time with the vertebrate mitochondrial genetic code. Notice that there are now two much larger ORFs on the first reading frame: One starting at position 4471 and the other starting at 5905. These correspond to the ND2 (NADH dehydrogenase subunit 2) and COX1 (cytochrome c oxidase subunit I) genes.

```
orfs = seqshoworfs(mitochondria,'GeneticCode','Vertebrate Mitochondrial',...
    'alternativestart',true)
```

orfs =

<http://matlab.udes.edu.co>

http://es.geocities.com/matlab_colombia/diamatlabnov3.html

<http://www.compelect.com.co/FormularioDiaMATLAB.html>

Start: [1x26 double]
Stop: [1x26 double]

Frame 1

```

000001 gatcacaggtctatcacccctattaaccactcacgggagctctccatgcatttggtatthtctc
000065 tggggggtgacgcgatagcattgagagcgtggagccggagcaccctatgtcgcagtatc
000129 tgtctttgattcctgcctcattctattatctatcgacactacgttcaatattacaggcgaacat
000193 acctactaaagtgtgtaattaattaatgctttaggacataataataacaattgaatgtctgc
000257 acagccgctttccacacagacatcataacaaaaatttccaccaaaccctcccccctc
000321 tctggccacagcacttaaacacatctctgcaaacccccaaaaacaaagaaccctaacaccagcc
000385 taaccagatttcaaattttatctttaggcggatgacacttttaacagtcacccccaactaaca
000449 cattatthtccctcccactcccataactactaactctcatcaatacaacccccgcccactacc
000513 cagcacacacacaccgctgtaacccataacccgaaccaaccaaaccctaaagacacccccca
000577 cagtttagtagcttacctctcaaagcaatacactgaaaatgtttagacgggctcacatcacc
000641 ccataacaaataggttggcttagccttctattagctcttagtaagattacacatgcaagc
000705 atccccgttccagtgagttcaccctctaaatcaccacgatcaaaagggacaagcatcaagcagc
000769 cagcaatgcagctcaaacgcttagccatagccacacccccacgggaaacagcagtgattaacct
000833 ttagcaataaacgaaagttaactaagctataactaacccagggttggtcaatttcgctgcagc
000897 acgcggtcacacgatcaacccaagtcaatagaagccggcgtaaaagagtggtttagatcacc
000961 cctcccaataaaagctaaaactcacctgagttgtaaaaaactccagttgacacaaaatagacta
001025 cgaaagtggcttaacatatctgaacacacaatagctaaagacccaaactgggattagatacccc
001089 actatgcttagccctaaacctcaacagttaaatcaacaaaactgctcgcagaaactacagagc
001153 cacagcttaaaactcaaggacctggcgggtgctcatatccctctagaggagcctgttctgtaa
001217 tcgataaaccccgatcaacctcaccacctctgctcagcctatataccgccatcttcagcaaac
001281 cctgatgaaggctacaagtaagcgcagtaaccacgtaaaagacgttaggtcaagggtgtagccc
001345 atgaggtggcaagaaatgggctacatthtctaccccagaaaactacgatagcccttatgaaact
001409 taagggctcgaaggtgatttagcagtaaacctgagagtagagtgcttagttgaacagggccctga
001473 agcgcgtacacaccgcccgtcacctctcaagataacttcaaggacatttaactaaaacccc
001537 tacgcatttatatagaggagacaagtcgtaacatggtaagtgtactggaaagtgcacttgagc
001601 aaccagagtgtagcttaacacaaagcacccttaacttaggagatttcaacttaacttgac
001665 cgctctgagctaaacctagccccaaacccactccaccttactaccagacaaaccttagccaaacc
001729 atttacccaaataaagtataggcgatagaaattgaaacctggcgcaatagatatagtagccga
001793 gggaaagatgaaaaattataaccaagcataatataagcaaggactaacccctataccttctgcat
001857 aatgaattaactagaaaataactttgcaaggagagccaaagctaagacccccgaaaccagacgag
001921 ctacctaagaacagctaaaagagcacaccctctatgtagcaaaaatagtgggaagatttatagg
001985 tagaggcgacaaacctaccgagcctgggtgatgctggttggtccaagatagaatcttagttcaac
002049 tttaaatttgcccacagaacctctaaatcccttgtaaaatttaactgttagtccaaagaggaa
002113 cagctctttggacactaggaaaaaacctgttagagagagtaaaaaatttaacaccatagtagg
002177 cctaaaagcagccaccaatlaagaaagcgttcaagctcaacaccactacctaataaaatcccaa
002241 acatataactgaaactcctcacacccaattggaccaatctatcacctatagaagaactaatggt
002305 agtataagtaacatgaaaacattctcctccgcaatagcctgcgctcagatcaaacactgaactg
002369 acaattaacagcccaatatctacaatcaaccaacaagtcattattacctcactgtcaacccaa
002433 cacaggcatgctcataaggaaaggttaaaaaagtaaaaggaactcggcaaaccttaccctgcc
002497 tgtttaccaaataacatcacctctagcatcaccagatttagaggcaccgctgcccagtgacaca
002561 tggttaacggcggcggtaaccttaacgtgcaaaaggtagcataatcactgttcccttaaatagg
002625 acctgatgaaaggctccacgagggttcagctgtctcttacttttaaccagtgaaattgacctg
002689 cccgtgaaggcgggcatgacacagcaagcagagaagaccctatggagctttaatttattaat
002753 gcaaacagctacctaacaacccacaggtcctaaactaccaaacctgcattaaaaatttcggttg
002817 gggcgacctcggagcagaacccaacctccgagcagtagctgtaagacttcaccagtcgaagcg
002881 aactactatactcaattgatccaaacttgaccaacggaacaagttacctagggataacagc
002945 gcaatcctattctagagtcocatatacaaataggggttacgacctcagtggtggatcaggacat
003009 ccgatggtgacgcgctatlaaggttcggttggtcaacgataaagtcctacgtgatctgag
003073 ttcagaccggagtaatccaggtcggttctatctacttcaaatctcctcctgtacgaaggaca
003137 agagaataaggcctactcacaagcgcctcccccgtaaatgatatactcacttagtat

```


PONENCIA # 4

003201 tataccacaccaccaagaacagggtttgttaagatggcagagcccggtaatcgcaataaaac
003265 ttaaaacttttacagtcagagggttcaattcctcttcttaacaacataccatggccaacctcta
003329 ctctcattgtaccatttctaatacgcaatggcattcctaattgcttaccgaacgaaaaattctag
003393 gctatatacaactacgcaaaggcccaacggttgtagggccctacgggctactacaacctctcgc
003457 tgacgccataaaactcttcaccaagagcccctaaaacccgcccacatctaccatcacctctac
003521 atcaccgccccgaccttagctctcaccatcgcctcttctactatgaacccccctccccataccca
003585 accccctggtaacctcaacctaggcctcctattttattctagccaccttagccttagccgttta
003649 ctcaatcctctgatcagggtgagcatcaaactcaaactacgcctgatcggcgcactgcgagca
003713 gtgcccacaacatctcatatgaagtcaccctagccatcattctactatcaacattactaataa
003777 gtggctcctttaacctctccaccttatcacacaagaacacctctgattactcctgcaac
003841 atgaccttggccataatgatgatttctccacactagcagagaccaaccgaacccccctcgac
003905 cttgcccgaaggggagtcggaactagctcaggcttcaacatcgaatacgcgcagggccccctcg
003969 cctattctctcatagccgaatacacaacattattataataaacacctcaccactacaactct
004033 cctaggaacaacatagagcactctcccctgaactctacacaacatatttgtcaccagacc
004097 ctacttctaacctcctgcttctatgaattcgaacagcataccocgattccgctacgaccaac
004161 tcatacactcctatgaaaaaacttctaccactcaccctagcattacttatatgatatgtctc
004225 cataccattacaatctccagcattccccctcaaacctaagaaatagtctgataaaagagtta
004289 ctttgatagagtaataataggagcttaaaccccccttatttctaggactatgagaatcgaacc
004353 atccctgagaaatcccaaatctcggcctacacacccccctctaaagtaaggctcagcta
004417 aataagctatcggccatacaccgcaaatggtgggtatacccttcccgtactaattaatcccc
004481 tggccaaccctcatctactctaccatctttgaggcacactcatcacagcgttaagctcgca
004545 ctgattttttacctgagtaggcttagaataaacatgctagctttttattccagttctaaccaaa
004609 aaaataaacctcgttccacagaagctgccatcaagtatttctcagcaagcaaccgcatcca
004673 taatccttctaatagctatcctcttcaacaatatactctccggcaatgaaccataaccaatac
004737 taccatcaatactcatcattaataatcataatggctatagcaataaaaactaggaatagcccc
004801 tttcacttctgagtcaccagaggttacccaaggcaccctctgacatccggcctgcttctctca
004865 catgcaaaaactagccccatctcaatcatatacaaatctctccctcaataacgtaagcct
004929 tctcctcaactctcaatcttctcactatagcaggcagttgaggtgattaaaccaaacccag
004993 ctacgcaaatcttagcatactcctcaattaccacataggatgaataatagcagttctaccgt
005057 acaaccctaacataaccattcttaatttaactatttatattatcctaactactaccgattcct
005121 actactcaacttaactccagcaccacgacctactactatctcgcacctgaacaagctaaca
005185 tgactaacacccttaattccatccaccctcctcctccttaggaggcctgccccgctaaccggct
005249 ttttgcccaaatggccattatcgaagaattcacaaaaacaatagcctcatcatccccaccat
005313 catagccaccatcaccctccttaacctctacttctacctacgcctaactctactccacctcaatc
005377 acactactccccatatacaaacgtaaaaaataaatgacagtttgaacatacaaaaaccaccc
005441 cattctccccactcatcgccttaccacgctactcctactatctcccctttatacctaata
005505 aatcttatagaaatttaggttaaatcacagccaagagccttcaagccctcagtaagttgcaat
005569 acttaatttctgcaacagctaaggactgcaaacccccactctgcatcaactgaacgcaaatcag
005633 ccactttaattaagctaagcccttactagaccaatgggacttaaacccacaaacacttagttaa
005697 cagctaagcaccctaatacaactggcttcaatctacttctcccgcgcccgggaaaaaaggcggga
005761 gaagccccggcaggttgaagctgcttctcgaatttgcaattcaatgaaaatcacctcgga
005825 gctggtaaaaagagccctaaccctgtcttagatttacagtcfaatgcttcaactcagccattt
005889 tacctcaccctcctgattgctcgcgaccttgactattctctacaaaaccacaaagacattgga
005953 acactatacctattattggcgcatgagctggagtcctaggcacagctctaagcctccttattc
006017 gaggcagctgggcccagccaggcaacctctaggtaacgaccacatctacaacgcttatcgtcac
006081 agcccatgatttgaataatcttctcatagtaatacccatcataatcggaggcttggcaac
006145 tgactagttcccataataatcgggtgccccgatatggcgcttcccgcataaacaacataagct
006209 tctgactcttacctcctctctcctactcctgctcgcctctgctatagtgaggcgggagcagg
006273 aacaggttgaacagctcaccctccttagcagggaactactcccacctggagcctccgtagac
006337 ctaaccatcttctccttacacctagcaggtgtcctctatcttagggccatcaatctcatca
006401 caacaattatcaatataaaacccccctgcataaaccatacaaacgccccctctcgtctgatc
006465 cgtcctaatacagcagctcctacttctcctatctctcccagtcctagctgctggcatcactata
006529 ctactaacagaccgcaacctcaacaccaccttcttgacccccgcccggaggaggagacccccattc
006593 tataccaacactattctgatttttcggtcaccctgaagtttatattcttatcctaccagctt
006657 cgaataatctcccatattgtaacttactactcggaaaaaagaaccatttggatacataggt
006721 atggctctgagctatgatataatggctcctagggtttatcgtgtgagcacaccatataat
006785 cagtaggaatagacgtagacacagcagcatabttcacctccgctaccataatcatcgtatccc
006849 caccggcgtcaaagtatttagctgactcgccacactccacggaagcaatgaaatgatctgct

```
006913 gcagtgtctgagccctaggattcatctttctttccacgtaggtggcctgactggcattgtat
006977 tagcaaacctcatcactagacatcgactacacgacacgtagctactcgtttagctcacttccacta
007041 tgtcctatcaataggagctgtatttgccatcataggaggcttcattcactgatttcccctattc
007105 tcaggctacaccctagaccaaactacgccaaaatccatttcactatcatattcatcggcgtaa
007169 atctaactttcttcccacaacactttctcggcctatccggaatgccccgacgttactcggacta
007233 ccccgatgcatacaccacatgaaacatcctatcatctgtaggctcatcatttctctaacagca
007297 gtaatattaataattttcatgatttgagaagccttcgcttcgaagcgaagcctaataatagta
007361 aagaaccctccataaacctggagtgactatattggatgccccccaccctaccacacattcgaaga
007425 acccgtatacataaaaatctagacaaaaaaggaaggaatcgaaccccccaagctggtttcaagc
007489 caaccccatggc
```

Extracting and analyzing the ND2 protein

The ORF of interest starts at position 4471, the following commands can be used to find the corresponding stop codon:

```
ND2Start = 4471;
startIndex = find(orfs(1).Start == ND2Start)
ND2Stop = orfs(1).Stop(startIndex)
startIndex =
```

24

ND2Stop =

5512

Once the positions are known, MATLAB indexing can be used to extract the region of interest.

```
ND2Seq = mitochondria(ND2Start:ND2Stop);
```

If you look at the **codoncount** for this gene we see a lot of CTA and ATC codons.

```
codoncount(ND2Seq)
AAA - 10    AAC - 14    AAG - 2    AAT - 6
ACA - 11    ACC - 24    ACG - 3    ACT - 5
AGA - 0     AGC - 4    AGG - 0    AGT - 1
ATA - 22    ATC - 24    ATG - 2    ATT - 8
CAA - 8     CAC - 3    CAG - 2    CAT - 1
CCA - 4     CCC - 12    CCG - 2    CCT - 5
CGA - 0     CGC - 3    CGG - 0    CGT - 1
CTA - 26    CTC - 18    CTG - 4    CTT - 7
GAA - 5     GAC - 0    GAG - 1    GAT - 0
GCA - 8     GCC - 7    GCG - 1    GCT - 4
GGA - 5     GGC - 7    GGG - 0    GGT - 1
GTA - 3     GTC - 2    GTG - 0    GTT - 3
TAA - 0     TAC - 8    TAG - 0    TAT - 2
TCA - 7     TCC - 11    TCG - 1    TCT - 4
TGA - 10    TGC - 0    TGG - 1    TGT - 0
TTA - 8     TTC - 7    TTG - 1    TTT - 8
```

PONENCIA # 4

For those of you who have not memorized the genetic code you can easily check what amino acids these codons get translated into using the **nt2aa** and **aminolookup** functions.

```
aminolookup('letter',nt2aa('CTA'))
aminolookup('letter',nt2aa('ATC'))
ans =

Leu      leucine
```

```
ans =

Ile      isoleucine
```

The **nt2aa** function converts the nucleotide sequence to the corresponding amino acid sequence. Again the 'GeneticCode' option must be used to specify the vertebrate mitochondrial genetic code.

```
ND2 = nt2aa(ND2Seq,'GeneticCode','Vertebrate Mitochondria');
```

You can get a more complete picture of the amino acid content with **aaccount**.

```
figure
aaccount(ND2,'chart','bar')
ans =

A: 20
R: 4
N: 20
D: 0
C: 0
Q: 10
E: 6
G: 13
H: 4
I: 31
L: 64
K: 12
M: 25
F: 15
P: 23
S: 28
T: 43
W: 11
Y: 10
V: 8
```

Notice the high leucine, threonine and isoleucine content and also the lack of cysteine or aspartic acid.

You can use the **atomiccomp** and **molweight** functions to find out more about the ND2 protein.

PONENCIA # 4

```
atomiccomp(ND2)  
molweight(ND2)  
ans =
```

```
C: 1818  
H: 2882  
N: 420  
O: 471  
S: 25
```

```
ans =
```

```
3.8960e+004
```

For further investigation of the properties of the ND2 protein, try using **proteinplot**. This is a graphical user interface (GUI) that allows you to easily create plots of various properties, such as hydrophobicity, of a protein sequence. Click on the "Help" menu in the GUI for more information on how to use the tool.

```
proteinplot(ND2)
```

3. ANÁLISIS FILOGENÉTICO

- Proceso que usamos para determinar la relación evolutiva entre organismos.
- Estos resultados pueden dibujarse en un diagrama jerárquico llamado filograma (árbol filogenético)

EJEMPLO: CONSTRUCCIÓN DE UN ARBOL FILOGENÉTICO

- Usamos datos de secuencias mitocondriales (D-loop), creamos un árbol filogenético para una familia de primates.
- A partir de secuencias mitocondriales DNA (mtDNA) para la familia HOMINIDAE.

3.1. BÚSQUEDA DE DATOS FILOGENÉTICOS EN NCBI

PROCEDIMIENTO

- Use the MATLAB Help browser to search for data on the Web. In the MATLAB Command Window, type `web('http://www.ncbi.nlm.nih.gov')`
- Buscar el sitio web NCBI para información
- Seleccionar el link taxonomy para la familia HOMINIDAE

3.2. CREACIÓN DE UN ARBOL FILOGENÉTICO PARA CINCO ESPECIES

- Crear una estructura MATLAB con información acerca de las secuencias.
- Se emplean códigos de acceso para las secuencias mitocondriales D-loop aisladas de especies homínidas diferentes.

```
data = {'German_Neanderthal' 'AF011222';  
        'Russian_Neanderthal' 'AF254446';  
        'European_Human'      'X90314' ;
```

<http://matlab.udes.edu.co>

http://es.geocities.com/matlab_colombia/diamatlabnov3.html

<http://www.compelect.com.co/FormularioDiaMATLAB.html>

```
'Mountain_Gorilla_Rwanda' 'AF089820';
'Chimp_Troglodytes'      'AF176766';};
```

- Obtener secuencias de datos de la base de datos GenBank y copiarlas en MATLAB

```
for ind = 1:5
    seqs(ind).Header = data{ind,1};
    seqs(ind).Sequence = getgenbank(data{ind,2},
                                    'sequenceonly', true);
end
```

- Se calculan las distancias de parejas discretas y se crea un objeto **phytree**

```
distances = seqpdist(seqs,'Method','Jukes-Cantor','Alphabet','DNA');
tree = seqlinkage(distances,'UPGMA',seqs)
```

- MATLAB dibuja un árbol filogenético

```
h = plot(tree,'orient','bottom');
ylabel('Evolutionary distance')
set(h.terminalNodeLabels,'Rotation',-45)
```

3.3. CREACION DE UN ARBOL FILOGENÉTICO PARA DOCE ESPECIES

- Se adicionan más secuencias a la estructura MATLAB

```
data2 = {'Puti_Orangutan'      'AF451972';
         'Jari_Orangutan'     'AF451964';
         'Western_Lowland_Gorilla' 'AY079510';
         'Eastern_Lowland_Gorilla' 'AF050738';
         'Chimp_Schweinfurthii'  'AF176722';
         'Chimp_Vellerosus'     'AF315498';
```

<http://matlab.udes.edu.co>

http://es.geocities.com/matlab_colombia/diamatlabnov3.html

<http://www.compelect.com.co/FormularioDiaMATLAB.html>

```
'Chimp_Verus'      'AF176731';
                    };
```

- Obtener las secuencias adicionales de datos adicionales de la base de datos GenBank.

```
for ind = 1:7
    seqs(ind+5).Header = data2{ind,1};
    seqs(ind+5).Sequence = getgenbank(data2{ind,2},
                                     'sequenceonly', true);
end
```

- Se calculan las distancias pares iguales y el apareamiento jerárquico

```
distances = seqpdist(seqs,'Method','Jukes-Cantor','Alpha','DNA');
tree = seqlinkage(distances,'UPGMA',seqs);
```

- MATLAB dibuja un árbol filogenético

```
h = plot(tree,'orient','bottom');
ylabel('Evolutionary distance')
set(h.terminalNodeLabels,'Rotation',-45)
```

4. Referencias:

- 4.1. BioinformaticsToolboxForUsewithMATLAB®, User Guide, V. 21.1, The MathWorks Inc. 2005.
- 4.2. MATLAB 7.1, Release 14 Service Pack 3, The MathWorks Inc. 2005.
- 4.3. Bioinformatics Toolbox 2.1.1. The MathWorks Inc. , Septiembre 2005,