

APLICACIÓN DE TÉCNICAS DE OPTIMIZACIÓN Y BIG DATA AL PROBLEMA DE BÚSQUEDA DE HOMOLOGÍAS EN BASES DE DATOS BIOLÓGICAS

Gabriel Antonio Valverde Castilla
Dra. Beatriz González-Pérez
Dra. Victoria López López



VII Jornadas de Usuarios de R
5 y 6 de Noviembre de 2015
Salamanca



CONTENIDO

Motivación y objetivos

Bases de datos

Alineamiento de Secuencias


Algoritmos

Implementación

Resultados



Motivación



Paquetes de R

Paquete	Descripción	Funciones de interés
<code>seqinr</code>	Análisis exploratorio y visualización de datos de secuencias biológicas.	<code>Read.fasta</code> , <code>write.fasta</code> , <code>s2c</code> , <code>c2s</code> , <code>dotplot</code> , <code>query...</code>
<code>Biostrings</code>	Algoritmos de alineamiento y utilidades para la manipulación eficiente de largas secuencias biológicas.	<code>readFASTA</code> , <code>writeFASTA</code> , <code>pairwiseAlignment</code> , <code>getTrans...</code>
<code>ff</code>	Estructuras de almacenamiento masivo de datos.	<code>Ff</code> , <code>ffsave</code> , <code>ffload</code> , <code>open.ff</code>
<code>Data.table</code>	Versión mejorada de los <code>data.frame</code> de R. Con algoritmos de consultas más veloces basados en B-tree.	<code>All.equal</code> , <code>:=</code> , <code>between</code> , <code>in</code> , <code>chmatch</code> , <code>duplicated</code> , <code>fread</code> , <code>melt.data.table</code> , <code>rbindlist</code> ...
<code>PLYR</code>	Como <code>data.table</code> nos permite hacer consultas más veloces sobre <code>data.frame</code> . Basándose en Split + Combine.	<code>Ddply</code> , <code>lply</code> .
<code>doParallel</code>	Permite la paralización multicores de máquina de algoritmos.	<code>Mclapply</code> , <code>registerDoParallel</code> , <code>stopImplicitCluster</code> .
<code>RHADOOP</code>	Permite la interacción ente R y Hadoop, basado en el modelo de programación MapReduce	<code>Rmr</code> , <code>RHDFS</code> , <code>RBASE</code> , <code>PLYRR</code> <code>Mapreduces</code> , <code>hdfs.init</code> , <code>hdfs.put</code> , <code>hdfs.get</code> , ...



Bases De Datos

- NoSql
 - Nuevo sistema de bases de datos más genérico que los convencionales buscando rendimiento, velocidad y generalidad.
- Genómica
 - Pioneros en las bases de datos abiertas concienciados con su valor. NCBI EBI. Genbank 28.000 millones de pares de bases (nucleótidos), correspondientes a más de 22 millones de secuencias
- Fasta
 - Formato genérico para tratar con datos de secuencias de nucleótidos y aminoácidos que hemos utilizado.



FASTA

```
>gi|5524211|gb|AAD44166.1| cytochrome b [Elephas maximus maximus]
LCLYTHIGRNIYYGSYLYSETWNTGIMLLITMATAFMGYVLPWGQMSFWGATVITNLFSAIPYIGTNLV
EWIWGGFSVDKATLNRFFAFHFILPFTMVALAGVHLTFLHETGSNNPLGLTSDSDKIPFHPYYTIKDFLG
LLILILLLLLLLALLSPDMLGDPDNHMPADPLNTPLHIKPEWYFLFAYAILRSVPNKLGGVLALFLSIVIL
GLMPFLHTSKHRSMMLRPLSQALFWTLTMDLLTLTWIGSQPVEYPYTIIGQMASILYFSIILAFPLPIAGX
IENY
```


```
> choosebank("genbank")
> ccnd3hs <- query("ccnd3hs", "sp=homo sapiens AND k=ccnd3@")
> sapply(ccnd3hs$req, getName)
[1] "AF517525.CCND3" "BC011616.CCND3" "CR542246" "HUMCCND3A.CCND3"
[5] "HUMCCND3PS.PE1" "HUMCCND3B04.CCND3" "HUMCYCD3A.CCND3"
> sapply(ccnd3hs$req, getLength)
[1] 879 879 879 879 537 559 879
> getSequence(ccnd3hs$req[[2]])[1:30]
[1] "a" "t" "g" "g" "a" "g" "c" "t" "g" "c" "t" "g" "t" "g" "t" "t" "g" "c" "g" "a" "a"
[22] "g" "g" "c" "a" "c" "c" "c" "g" "g"
> getTrans(ccnd3hs$req[[2]])[1:30]
[1] "M" "E" "L" "L" "C" "C" "E" "G" "T" "R" "H" "A" "P" "R" "A" "G" "P" "D" "P" "R" "L"
[22] "L" "G" "D" "Q" "R" "V" "L" "Q" "S"
```

■ Biostrings

■ Seqin




Alineamiento de Secuencias



Alineamiento Global

Algoritmo de Needleman-Wunsch

Secuencias parecidas, de longitud semejante
Intenta alinear todos los elementos



Alineamiento Global



Alineamiento Local

Alineamiento Local

Algoritmo Smith-Waterman

Divergencia estructural

Características puntuales similares

2 SECUENCIAS NO ALINEADAS

L	G	P	S	S	K	Q	T	G	K	G	S	S	R	I	W	D	N
L	N	I	T	K	S	A	G	K	G	A	I	M	R	L	G	D	A

ALINEAMIENTO GLOBAL

L	G	P	S	S	K	Q	T	G	K	G	S	-	S	R	I	W	D	N
L	N	-	I	T	K	S	A	G	K	G	A	I	M	R	L	G	D	A

ALINEAMIENTO LOCAL

-	-	-	-	-	-	-	T	G	K	G	-	-	-	-	-	-	-	-
-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-

Matriz de Puntuación

	A	R	N	D	C	Q	E	G	H	I	L	K	M	P	F	S	T	W	V	B	X	*		
A	4	-1	-2	-2	0	-1	-1	0	-2	-1	-1	-1	-1	-2	-1	1	0	-3	-2	0	-2	-1	0	-4
R	5	0	-2	-3	1	0	-2	0	-3	-2	2	-1	-3	-2	-1	-1	-3	-2	-3	-1	0	-1	-4	
N	2	6	1	-3	0	0	0	1	-3	-3	0	-2	-3	-2	1	0	-4	-2	-3	3	0	-1	-4	
D	-2	6	6	-3	0	2	-1	-1	-3	-4	-1	-3	-3	-1	0	-1	-4	-3	-3	4	1	-1	-4	
C	0	0	2	9	-3	-4	-3	-3	-1	-1	-3	-1	-2	-3	-1	-1	-2	-2	-1	-3	-3	-2	-4	
Q	0	-1	2	4	5	2	-2	0	-3	-2	1	0	-3	-1	0	-1	-2	-1	-2	0	3	-1	-4	
E	-2	-4	-4	-5	12	5	-2	0	-3	-3	1	-2	-3	-1	0	-1	-3	-2	-2	1	4	-1	-4	
G	0	1	1	2	-5	4	6	-2	-4	-4	-2	-3	-3	-2	0	-2	-2	-3	-3	-1	-2	-1	-4	
H	0	-1	1	3	-5	2	4	8	-3	-3	-1	-2	-1	-2	-1	-2	-2	-2	-3	0	0	-1	-4	
I	1	-3	0	1	-3	-1	0	5	4	-2	-3	1	0	-3	-2	-1	-3	-1	3	-3	-3	-1	-4	
L	-1	2	2	1	-3	3	1	-2	6	4	-2	2	0	-3	-2	-1	-2	-1	1	-4	-3	-1	-4	
K	-1	-2	-2	-2	-2	-2	-3	-2	5	5	-1	-3	-1	0	-1	-3	-2	-2	0	1	-1	-4	-4	
M	-2	-3	-3	-4	-6	-2	-3	-4	-2	2	6	5	0	-2	-1	-1	-1	-1	1	-3	-1	-1	-4	
P	-1	3	1	0	-5	1	0	-2	0	-2	-3	5	6	-4	-2	-2	1	3	-1	-3	-3	-1	-4	
F	-1	0	-2	-3	-5	-1	-2	-3	-2	2	4	0	6	7	-1	-1	-4	-3	-2	-2	-1	-2	-4	
S	-4	-4	-6	-4	-5	-5	-5	-2	1	2	-5	0	9	4	1	-3	-2	-2	0	0	0	-4	-5	
T	1	0	-1	-1	-3	0	-1	-1	0	-2	-3	-1	-2	-5	6	5	-2	-2	-1	-1	0	-4	-4	
W	1	0	1	0	0	-1	0	-1	1	-1	-3	0	-2	3	1	12	-3	-3	-4	-3	-2	-4	-4	
V	1	-1	0	0	-2	-1	0	0	-1	0	-2	0	-1	-3	0	1	3	7	-1	-3	-2	-1	-4	
B	-6	-2	-4	-7	-8	-5	-7	-7	-3	-5	-2	-3	-4	0	-6	-2	-5	17	4	-3	-2	-1	-4	
X	-3	-4	-2	-4	0	-4	-4	-5	0	-1	-1	-4	-2	7	-5	-3	0	10	4	1	-1	-4	-4	
*	0	-2	-2	-2	-2	-2	-1	-2	-4	2	-2	2	-1	-1	-1	0	-6	-2	4	4	1	-4	-5	
	0	-1	2	3	-4	1	2	0	1	-2	-3	1	-2	-5	1	0	0	-5	-3	-2	2	-1	-4	
	0	0	1	3	-5	3	3	-1	2	-2	-3	0	-2	-5	0	0	-1	-6	-4	-2	2	3	1	
	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	

Matriz **pam250** (inferior izquierda) y **BLOSUM62** (superior derecha) para proteínas



Algoritmo: Needleman - Wunsch

		H	E	A	G	A	W	G	H	E	E
	0	-8	-16	-24	-32	-40	-48	-56	-64	-72	-80
P	-8	-2	-9	-17	-25	-33	-41	-49	-57	-55	-73
A	-16	-10	-3	-4	-12	-20	-28	-36	-44	-52	-60
W	-24	-26	-11	-6	-7	-15	-5	-13	-21	-29	-37
H	-32	-14	18	-13	-8	-9	-13	-7	-3	-11	-19
E	-40	-22	-8	-16	-16	-9	-12	-15	-5	3	-5
A	-48	-80	-16	-3	-11	-11	-12	-12	-15	-5	2
E	-56	-38	-24	-11	-6	-12	-14	-15	-12	-9	1

$$t_{ij} = \max(t_{i-1,j-1} + s(x_i, y_j), t_{i,j-1} + d, t_{i,j-1} + d)$$

$s(x_i, y_j)$ = valor matriz de sustitución
Blosum62 en nuestro caso

$$t_{23} = \max(t_{12} + s(x_P, y_E), t_{2,2} + d, t_{2,3} + d)$$

$$t_{23} = \max(-8 + 1, -2 - 8, -16 - 8) = -9$$

H E A G A W G H E _ E
_ _ A _ A W _ H E A E


H E A G A W G H E _ E
_ P A _ _ W _ H E A E

Al realizar alineamiento de secuencias hemos de tener en cuenta:


- ▣ Tipo de alineamiento
- ▣ ADN (más sensible) o traducción
- ▣ Elegir un sistema de puntuaciones adecuado. PAM BLOSUM.
- ▣ Métodos estadísticos para explicarlo.



Implementación



Método I: R Localmente




Método I: R Localmente

■ Librerías de R utilizadas:

PAQUETE DE R	DEFINICION	FUNCIONES
Data.Table [14R]	Paquete que mediante el uso de árboles binarios y otras forma de optimización en el uso de índices, ha mejorado el rendimiento de los objetos data.frame. Nos permite hacer operaciones típicas de las bases de datos, como son select, where, by, y crear nuevas columnas de forma ágil.	As.data.table: Convierte en data.table otros objetos de r. .SD: permite aplicar una función a varias columnas de un data.table. setkey: Permite definir una columna como clave para realizar operaciones por grupo.
Plyr	Facilita el cálculo vectorial y también consta de distintas funciones típicas de la gestión de bases de datos. Existe una versión para trabajar con Hadoop.	Ddply, permite crear nuevas variables a partir de las variables que forman el conjunto de datos.
parallel	Nos permite realizar paralelización local en el número de nodos de forma transparente en R.	Foreach, aplica un for sobre el conjunto definido, fragmentando el conjunto de datos en memoria para establecer acceso distribuido en función de los nodos.




Método : MapReduce R + Hadoop



HDFS

Lectura de datos HDFS




- Sistema de distribución de archivos de Hadoop. Ventajas:
 - Crecimiento horizontal vs problemas de espacio.
 - Replicas vs Fallos del sistema.
 - Distribución vs Tiempo de acceso
 - Paralelización vs Tiempo de ejecución
- Inconvenientes:
 - Elevada latencia con pequeños datos
 - Cambios se introducen siempre al final
 - No se permite escritura simultanea sobre ficheros




HDFS

Escritura de datos HDFS




MapReduce



Nombre	Función
INPUT	Directorio de los datos de entrada que pueden provenir tanto de HDFS, incluidos por medio de la función to.dfs, como de la salida de otro mapreduce.
OUTPUT	Directorio de HDFS donde queremos que se almacenen, si es vacío puede ser enviado a un nuevo map, reduce, or from.dfs
MAP	Una función de R que recibe dos valores como entrada, clave y valor. Devuelve con la misma estructura. keyval(k, v, vectorized = FALSE) Es su principal aliada, es la función que ayuda a definir estás parejas.
Reduce	Función que se aplica a la salida del map y devuelve agrupado los resultados por claves.
Make.input/output.format	Permite crear los formatos de los datos de entrada,
Imput/output.format	Permite definidor los formatos de forma que puedan ser transformados al único que soporta Hadoop Streaming.
Vectorized	Permite procesar múltiples registros al mismo tiempo, en lugar de línea a línea.
backend	Parámetros adicionales de Hadoop, como son las limitaciones de memoria, el número de tareas por nodo,... Nos permite seleccionar trabajar en local para hacer debug de código.
To.map /to.reduce	Convierte cualquier función en una función apta para aplicar en este proceso. Incluyendo una función referente a value y otra a key.



Escenario



http://www.uniprot.org/uniprot/Q6GZX4?version=*



Salida Local

```
> head(Puntuaciones,9)
```

	Names	puntuaciones
1:	sp P83570 GWA_SEPOF	2
2:	sp P84761 ACI_TRIGI	3
3:	sp P83568 ILME_SEPOF	3
4:	sp P24272 LUXE_VIBFI	3
5:	sp P62970 TRH_BOMOR	3
6:	sp P62971 TRH_NOTVI	3
7:	sp P62968 TRH_PIG	3
8:	sp P62969 TRH_SHEEP	3
9:	sp P35904 ACH1_ACHFU	4

```
> tail(Puntuaciones,9)
```

	Names	puntuaciones
1:	sp Q8NF91 SYNE1_HUMAN	256
2:	sp Q6ZWR6 SYNE1_MOUSE	256
3:	sp Q8WXH0 SYNE2_HUMAN	256
4:	sp Q9I7U4 TITIN_DROME	256
5:	sp Q8WZ42 TITIN_HUMAN	256
6:	sp A2ASS6 TITIN_MOUSE	256
7:	sp O30409 TYCC_BREPA	256
8:	sp Q6GZX4 001R_FRG3G	256
9:	sp Q23551 UNC22_CAEEL	256



Salida RHadoop

V1	Cadena:
1: 247	sp P25464 ACVS_ACRCH,sp Q12955 ANK3_HUMAN,sp Q9M3G7 ATM_ARATH,sp Q8IID4 DYHC2_PLAF7,sp P58107 EPIPL_HUMAN,sp P97412 LYST_MOUSE,
2: 248	sp Q20911 CUBN_CAEEL,sp Q9SMH5 DYHC2_CHLRE,sp O88277 FAT2_RAT,sp Q8TDW7 FAT3_HUMAN,sp Q8R508 FAT3_RAT,sp Q6V0I7 FAT4_HUMAN,
3: 249	sp Q9MBF8 DYH1B_CHLRE,sp Q8BW94 DYH3_MOUSE,sp Q9C0G6 DYH6_HUMAN,sp Q19542 DYHC2_CAEEL,sp Q27171 DYHC_PARTE,sp P36022 DYHC_YEAST,
4: 250	sp P04114 APOB_HUMAN,sp Q96M86 DNHD1_HUMAN,sp A7X2C3 EBHA_STAA1,sp Q931R6 EBHA_STAAM,sp Q99U54 EBHA_STAAN,sp Q14517 FAT1_HUMAN,
5: 251	sp Q19319 CADH4_CAEEL,sp P0C6F1 DYH2_MOUSE,sp Q63170 DYH7_RAT,sp Q8IBG1 DYHC1_PLAF7,sp Q9C1M7 DYHC_ASHG0,sp P34036 DYHC_DICDI,
6: 252	sp Q5SSE9 ABCAD_MOUSE,sp Q7TMA5 APOB_RAT,sp O88738 BIRC6_MOUSE,sp Q69Z23 DYH17_MOUSE,sp Q9P2D7 DYH1_HUMAN,sp Q63164 DYH1_RAT,
7: 253	sp Q9SRU2 BIG_ARATH,sp Q9NR09 BIRC6_HUMAN,sp Q8IVF4 DYH10_HUMAN,sp Q96DT5 DYH11_HUMAN,sp Q9UFH2 DYH17_HUMAN,sp Q9SMH3 DYH1A_CHLRE,
8: 254	sp Q86UQ4 ABCAD_HUMAN,sp Q9N4M4 ANC1_CAEEL,sp B9G2A8 BIG_ORYSJ,sp Q8TE73 DYH5_HUMAN,sp Q8VHE6 DYH5_MOUSE,sp Q96JB1 DYH8_HUMAN,
9: 255	sp Q91XQ0 DYH8_MOUSE,sp A2ARZ3 FSIP2_MOUSE,sp Q8VHN7 GPR98_MOUSE,sp O95714 HERC2_HUMAN,sp Q01886 HTS1_COCCA,sp Q80W93 HYDIN_MOUSE,
10: 256	sp Q6GZX4 001R_FRG3G,sp C6KT87 ALH1_PLAF7,sp O68006 BACA_BACLI,sp O68008 BACC_BACLI,sp Q6GZX4 001R_FRG3G,sp Q54CU4 COLA_DICDI,



Salida RHadoop

[[1]]

[1] "sp|P25464|ACVS_ACRCH" "sp|Q12955|ANK3_HUMAN" "sp|Q9M3G7|ATM_ARATH" "sp|Q8IID4|DYHC2_PLAF7" "sp|P58107|EPIPL_HUMAN" "sp|P97412|LYST_MOUSE"
 [7] "sp|Q4WLW5|NRP12_ASPFU" "sp|Q4WAZ9|NRP14_ASPFU" "sp|P0C6F4|R1A_BRV1" "sp|Q9YN02|RPOA_PRRS1" "sp|Q8B912|RPOA_PRRSB" "sp|Q8I8U7|TRA1_DROME"
 [13] "sp|P38811|TRA1_YEAST" "sp|Q80TY5|VP13B_MOUSE"

[[2]]

[1] "sp|Q20911|CUBN_CAEEL" "sp|Q9SMH5|DYHC2_CHLRE" "sp|O88277|FAT2_RAT" "sp|Q8TDW7|FAT3_HUMAN" "sp|Q8R508|FAT3_RAT" "sp|Q6V0I7|FAT4_HUMAN"
 [7] "sp|Q8NEZ4|MLL3_HUMAN" "sp|Q83034|POLG_RTSVA" "sp|P78527|PRKDC_HUMAN" "sp|P0C6F6|R1A_BC512" "sp|P0C6V6|R1A_PEDV7" "sp|Q008X5|R1A_WBV24"
 [13] "sp|Q04561|RPOA_PRRSL" "sp|O43103|SID2_USTMA" "sp|Q9Y4A5|TRRAP_HUMAN" "sp|Q4U4S6|XIRP2_MOUSE"

[[3]]

[1] "sp|Q9MBF8|DYH1B_CHLRE" "sp|Q8BW94|DYH3_MOUSE" "sp|Q9C0G6|DYH6_HUMAN" "sp|Q19542|DYHC2_CAEEL" "sp|Q27171|DYHC_PARTE" "sp|P36022|DYHC_YEAST"
 [7] "sp|A6QGY5|EBHB_STAAE" "sp|Q9NYQ8|FAT2_HUMAN" "sp|Q5F226|FAT2_MOUSE" "sp|Q8BNA6|FAT3_MOUSE" "sp|Q8NDA2|HMCN2_HUMAN" "sp|Q66431|L_DUGBA"
 [13] "sp|Q8BRH4|MLL3_MOUSE" "sp|Q7TPH6|MYCB2_MOUSE" "sp|Q86WI1|PKHL1_HUMAN" "sp|Q96662|POLG_BVDVC" "sp|P19711|POLG_BVDVN" "sp|Q9DEI1|PRKDC_XENLA"
 [19] "sp|P0C6F7|R1A_BC133" "sp|P0C6F5|R1A_BC279" "sp|P0C6F8|R1A_BCHK3" "sp|P0C6T7|R1A_BCRP3" "sp|P0C6V1|R1A_CVMJH" "sp|P0C6V2|R1A_CVPPU"
 [25] "sp|P0C6V5|R1A_IBVM" "sp|Q9WJB2|RPOA_PRRSR" "sp|A0MD28|RPOA_PRRSS"

[[4]]

[1] "sp|P04114|APOB_HUMAN" "sp|Q96M86|DNHD1_HUMAN" "sp|A7X2C3|EBHA_STAA1" "sp|Q931R6|EBHA_STAAM" "sp|Q99U54|EBHA_STAAN" "sp|Q14517|FAT1_HUMAN"
 [7] "sp|Q2PZL6|FAT4_MOUSE" "sp|C6KTD2|HKNMT_PLAF7" "sp|Q9R9J1|MYCA_BACIU" "sp|O75592|MYCB2_HUMAN" "sp|Q80ZA4|PKHL1_MOUSE" "sp|Q01499|POLG_BVDVS"
 [13] "sp|P19712|POLG_CSFVA" "sp|P21530|POLG_CSFVB" "sp|P94459|PPSD_BACSU" "sp|Q8WN22|PRKDC_CANFA" "sp|P0C6T4|R1A_BCHK4" "sp|P0C6T8|R1A_CVBEN"
 [19] "sp|P0C6T9|R1A_CVBLU" "sp|P0C6U0|R1A_CVBM" "sp|P0C6U1|R1A_CVBQ" "sp|P0C6U3|R1A_CVHN1" "sp|P0C6U4|R1A_CVHN2" "sp|P0C6U5|R1A_CVHN5"
 [25] "sp|P0C6U8|R1A_CVHSA" "sp|Q80TF6|STAR9_MOUSE" "sp|Q5THJ4|VP13D_HUMAN" "sp|O88799|ZAN_MOUSE"

[[5]]

[1] "sp|Q19319|CADH4_CAEEL" "sp|P0C6F1|DYH2_MOUSE" "sp|Q63170|DYH7_RAT" "sp|Q8IBG1|DYHC1_PLAF7" "sp|Q9C1M7|DYHC_ASHG0" "sp|P34036|DYHC_DICDI"
 [7] "sp|Q8NWQ6|EBH_STAAN" "sp|Q5HPA2|EBH_STAEQ" "sp|Q8CP76|EBH_STAES" "sp|P33450|FAT_DROME" "sp|Q15751|HERC1_HUMAN" "sp|Q9VR91|HERC2_DROME"
 [13] "sp|A2AJ76|HMCN2_MOUSE" "sp|Q18DN4|HML_HALWD" "sp|Q9JI18|LRP1B_MOUSE" "sp|P98157|LRP1_CHICK" "sp|Q07954|LRP1_HUMAN" "sp|Q91ZX7|LRP1_MOUSE"
 [19] "sp|Q04833|LRP_CAEEL" "sp|Q6TQR6|L_CCHFI" "sp|Q12019|MDN1_YEAST" "sp|Q8QGX4|PRKDC_CHICK" "sp|P97313|PRKDC_MOUSE" "sp|P0C6F3|R1A_BEV"
 [25] "sp|P0C6U7|R1A_CVHOC" "sp|P0C6U9|R1A_CVM2" "sp|Q9P2P6|STAR9_HUMAN"




Comparativa

MODELO	5	10	50	100	500	1000	5000	10000	50000
Parallel.Data.Table	2.23	3.331	17.478	30.312	146.370	381.348	2555.176	6736.128	31940.7
Data.Table	2.448	15.162	25.104	123.121	232.023	1133.982	23009.212		
Plyr	13.43	21.046	110.6	202.194	983.3782	2612.60	20480.52		
Plyr + Doparallel	3.8	6.599	21.805	37.390	166.271	420.072	2694.451	7850.012	26675.06
RHadoop	120.352	115.142	117.367	95.604	125.883	196.19	661.689	1029.46	6171.976



Comparativa



Conclusión

- Cuantificar el alineamiento global de toda una base de datos de cadenas con una dada en busca de homología se ha conseguido.
- El tiempo de ejecución de este proceso ha sido reducido tanto en el modo local como en un clúster de máquinas.
- Comprobando la eficacia de Hadoop sobre una red de máquinas instauradas en la nube.
- Trabajo Futuro



GRACIAS

