

U N I V E R S I D A D D E G U A D A L A J A R A

CENTRO DE CIENCIAS BIOLÓGICAS Y AGROPECUARIAS

DIVISION DE CIENCIAS BIOLÓGICAS Y AMBIENTALES



CUCBA



BIBLIOTECA CENTRAL

“SECUENCIAS SIMPLES DE TRES GENOMAS MICROBIANOS:
IMPLICACIONES EN EL ORIGEN Y EVOLUCIÓN DE LAS PROTEÍNAS.

T E S I S P R O F E S I O N A L

QUE PARA OBTENER EL TITULO DE :

L I C E N C I A D O E N B I O L O G I A

P R E S E N T A :

MAGALY OLIVO HERNANDEZ

GUADALAJARA, JALISCO.,

1999



UNIVERSIDAD DE GUADALAJARA

CENTRO UNIVERSITARIO DE CIENCIAS BIOLÓGICAS Y AGROPECUARIAS

COORDINACIÓN DE CARRERA DE LA LICENCIATURA EN BIOLOGÍA

COMITÉ DE TITULACIÓN

**C. MAGALY OLIVO HERNANDEZ
PRESENTE.**

Manifiestamos a Usted que con esta fecha ha sido aprobado su tema de titulación en la modalidad de TESIS con el título **"SECUENCIAS SIMPLES EN TRES GENOMAS MICROBIANOS : IMPLICACIONES EN EL ORIGEN Y EVOLUCION DE LAS PROTEINAS"**, para obtener la Licenciatura en Biología.

Al mismo tiempo le informamos que ha sido aceptado como Director de dicho trabajo al **M.C. ARTURO CARLOS II BECERRA BRACHO** y como asesor al **DR. ANTONIO LAZCANO-ARAUJO REYES**.

A T E N T A M E N T E
" PIENSA Y TRABAJA "
LAS AGUJAS, ZAPOPAN JAL., MAYO 28 DE 1999

DR. ARTURO OROZCO BAROJO
PRESIDENTE DEL COMITÉ DE TITULACIÓN



M. EN C. MARTHA GEORGINA OROZCO MEDINA
SECRETARIO DEL COMITÉ DE TITULACIÓN

c.c.p. **M.C. ARTURO CARLOS II BECERRA BRACHO**.- Director del Trabajo.
c.c.p. **DR. ANTONIO LAZCANO-ARAUJO REYES**.- Asesor del Trabajo.
c.c.p. Expediente del alumno

AOB/MGOM/bacg*

Dr. ARTURO OROZCO BAROCIO
PRESIDENTE DE LA COMISIÓN DE TITULACIÓN
DIVISION DE CIENCIAS BIOLÓGICAS Y AMBIENTALES

PRESENTE.

Por este medio me permito comunicar a usted que habiendo revisado el trabajo de tesis "Secuencias simples de tres genomas microbianos: Implicaciones en el origen y evolución de las proteínas", preparado por la pasante de Biología Magaly Olivo Hernández con código 087556182 y del cual fungí como director, considero que ha sido concluido satisfactoriamente.

Por esta razón, puede proceder a la presentación de la tesis para su revisión en la División a su cargo y el examen profesional correspondiente.

ATENTAMENTE

"Por mi raza hablara el espíritu"

México, D.F., a 20 de Mayo de 1999

CUCBA



BIBLIOTECA CENTRAL

Director de Tesis

M.en C. Arturo Carlos II Becerra Bracho

A. Lazcano-Araujo

Asesor de Tesis

Dr. Antonio E. Lazcano-Araujo Reyes

Sinodales

Dr. Anne Santerre.

M. en C. Alfonso E. Islas. R.

Dr. Arturo Orozco Barocio.

ASanterre 28/05/99.
[Signature] 2/06/99.

AGRADECIMIENTOS

- Quiero agradecer en primera instancia al director de esta tesis el M. en C. Arturo Becerra Bracho por permitirme conocer el valor real de la investigación, por compartir conmigo sus conocimientos, y desde luego por su invaluable enseñanza, amistad, apoyo y paciencia durante el desarrollo de este trabajo sin olvidar el buen sentido del humor que tiene, asimismo su generosa ayuda durante mis estancias en el D.F. Arturo muchísimas gracias.
- Un agradecimiento muy especial al Dr. Antonio Lazcano por haberme aceptado en su laboratorio, por compartir sus conocimientos y estar pendiente de lo que sucede en su laboratorio, en el cual fue muy agradable trabajar por ese gran sentido del humor que lo caracteriza aparte de ser un gran investigador.
- A los compañeros del laboratorio: Luis, Sara, Ervin, Amanda, Héctor, Ana, Ulises, Rosana y Josextu por esa armonía que se siente al estar trabajando con ustedes, además de compartir el gusto de la investigación y la risa.
- A mis sinodales Dra. Anne Santerre L. al Dr. Arturo Orozco B. y al M. en C. Alfonso Islas R. por el interés que demostraron en este tipo de trabajos, por sus atinados comentarios y sugerencias.
- A las mujeres de mi casa mi abuela Micaela, mi madre Yolanda y mi hermana Raquel por ese enorme cariño, respeto y amor han tenido siempre para mí, además de su invaluable apoyo durante mi educación muchas gracias.
- A Luis Bernardo por su cariño, apoyo y su enorme paciencia lo que hizo más fácil y divertido este trabajo..
- A la fundación Becerra-Novoa por compartir su casa conmigo, también por todas sus atenciones durante las estancias que pase en el D.F. muchas gracias.
- Al Ing. Tino Granata L. quien me permitió realizar mi tesis en el centro de computo sin ningún costo, siendo siempre muy accesible.
- De igual manera a Angélica Velázquez por compartir conmigo sus conocimientos de computación y permitirme trabajar en horas poco accesibles aun en sus días de descanso muchas gracias Angy.
- A mis maestros José Luis Navarrete, Patricia Castro, Sergio Guerrero y Georgina Quiroz quienes aclararon siempre mis dudas dentro y fuera de clases, muchas gracias por invertir en mi educación.
- A mis amigas y compañeras de toda la licenciatura Lidia, Martha, Elia y Edith por compartir tantas aventuras.
- A los amigos del D.F. Bernardo, Paty, Arturo, Hugo, Lorena, Alex, Luis y David quienes compartieron la comida, el intercambio de ideas, la diversión y el gusto por la biología.

CUCBA



BIBLIOTECA CENTRAL

*A Luis Bernardo, compañero
de largos días y noches cortas.*

CUCBA



BIBLIOTECA CENTRAL

Este trabajo se realizó en el Laboratorio de Microbiología A-107 de la Facultad de Ciencias de la UNAM. Bajo la dirección del M. en C. Arturo Carlos Il Becerra Bracho con el apoyo del proyecto PAPIIT IN213598

ÍNDICE

Resumen.....	2
1. Introducción.	
1.1 Secuencias simples.....	3
1.2 Genómica y filogenias universales.....	7
1.3 Planteamiento.....	9
1.4 Objetivos.....	10
2. Material y métodos.....	11
3. Resultados.....	15
4. Discusión.....	44
4.1 Distribución de secuencias simples en los tres genomas microbianos.	
4.2 Consecuencias de la incorporación de las secuencias simples en el genoma.....	46
4.3 Distribución de los aminoácidos en las secuencias simples.....	47
5. Conclusión.....	48
6. Referencias.....	49
7. Apéndice.	
7.1 Formulario.....	55
7.2 Shell-Unix.....	57
7.3 Programa Seg.....	61
7.4 Programa SAPS.....	66
7.5 Matriz de puntos de las 86 secuencias simples de aminoácidos.....	76
8. Glosario.....	98

RESUMEN

Las secuencias simples (con baja complejidad composicional) se presentan en regiones codificantes, estas son producidas principalmente por el fenómeno conocido como *slippage-like* (patinaje de la polimerasa), incorporando sus productos en la proteína siendo una fuente de variabilidad genética.

Los análisis de las secuencias simples de los tres genomas microbianos completos de *Haemophilus influenzae*, *Methanococcus jannaschii* y *Saccharomyces cerevisiae* revelan que la baja complejidad tiene una amplia distribución en todos los grupos funcionales propuestos por Riley (1993); la composición, los segmentos cargados, los aminoácidos hidrofóbicos y de transmembrana, los multitiplotes, las estructuras repetidas, la periodicidad y la espacialidad que presentaron las secuencias simples revelan que no se tiene una correlación entre las propiedades físico-químicas y la función biológica, manteniendo diferentes estructuras secundarias en las proteínas que participan.

Dentro de las proteínas que presentan una baja complejidad se encontraron las ferredoxinas, DNA polimerasas ATP-sintetasas, topoisomerasas y ribosomales proteínas muy antiguas; de igual manera las secuencias simples se han visto involucradas en organismos patógenos y en enfermedades genéticas, lo que sugiere que el fenómeno del patinaje de la polimerasa es muy antiguo, estando presente en el último ancestro común a todos los seres vivos (*cenancestro*) y por lo tanto precede a la patogénesis.

La ocurrencia de las secuencias simples en varias funciones, la antigüedad de algunas proteínas y su presencia en los tres dominios, sugiere que el proceso de patinaje de la polimerasa no es solo un importante proceso en la evolución de genomas completos, sino también en el origen y evolución de las proteínas.

1. INTRODUCCION

1.1 Secuencias simples.

Las secuencias simples son regiones de DNA ó proteínas caracterizadas por una escasa variabilidad de sus componentes (nucleótidos y aminoácidos respectivamente), por lo que presentan una baja complejidad en términos de composición. Estas secuencias también son conocidas como: secuencias crípticas o microsátélites (está última sólo en DNA no codificante). Las secuencias simples se encuentran ampliamente distribuidas tanto en especies procariontes como eucariontes, en regiones no codificantes del material genético como en las codificantes, lo que ha sugerido que este tipo de secuencias tiene un papel importante en la evolución del tamaño de genomas y como fuente de variabilidad genética (Tauttz *et al.*, 1986; Hancock, 1995).

El análisis de las bases de datos de proteínas sugiere que el 25% de los residuos de aminoácidos presenta segmentos con sesgos composicionales y cerca del 50% de las proteínas contiene al menos una región con esta característica (Wootton, 1997). En los últimos años el interés por las secuencias simples se ha incrementado, dado su papel en diferentes fenómenos biológicos como: enfermedades genéticas, adaptabilidad de organismos patógenos (como *Neisseria gonorrhoeae* y *Haemophilus influenzae*) y determinación de parentesco entre poblaciones de especies silvestres (Moxon y Wills, 1999). Por otro lado, el estudio de este fenómeno puede ayudar a entender el origen y la evolución de las proteínas, así como el crecimiento y la variabilidad del material genético (Wootton, 1997).

Las secuencias simples son producidas principalmente por procesos tipo *slippage-like* (patinaje o tartamudeo de la polimerasa, Fig. 1), durante el proceso de la replicación del DNA y son reguladas por los mecanismos de reparación del DNA (Tautz y Schlötterer, 1994).




Fig. 1. Proceso tipo *slippage-like* o patinaje de la polimerasa, modificado de Moxon y Wills, (Scientific American, enero de 1999). a) el complejo de la DNA polimerasa separa la doble hélice del DNA copiando ambas hebras. La DNA polimerasa empieza a sintetizar pequeños fragmentos (1) inicia con un RNA primer, generando un fragmento pequeño, la DNA polimerasa se patina formando una horquilla, se siguen sintetizando fragmentos (2) cuando la polimerasa termina el fragmento, el RNA primer es removido y los dos fragmentos son unidos al DNA. Incrementando el número de repeticiones b) ocurre cuando la nueva hebra se patina provocando repeticiones, al ensamblarse con el molde viejo se ganan repeticiones en la nueva hebra c) sucede cuando las enzimas de reparación cortan las repeticiones.


Las secuencias simples pueden identificarse por tres propiedades: a) complejidad: propiedad computable, que resulta de la composición de la secuencia y permite hacer una representación generalizada de los sesgos composicionales; b) patrones: son secuencias sencillas caracterizadas por su contenido, su distribución de residuos y sus k-gramas (un k-grama es una palabra de k-letras); c) periodicidad: es la repetición de residuos o k-gramas a intervalos constantes (Wootton, 1997). (Cuadro 1).

Cuadro 1. Ejemplo de las propiedades de una secuencia simple (G_8A_8)

Complejidad	G A A G G A A A G G G A G A G A	sin patrón ni periodicidad
Periodicidad	G A G A G A G A G A G A G A G A	posee periodicidad y de ello resultan patrones de sus k-gramas
Patrón	G G A G G A A A A G G A A G G A	posee patrones (k-gramas) GGA y AGGA, pero su distribución es irregular y no muestra periodicidad

Estas propiedades pueden ser analizadas y cuantificadas por diferentes algoritmos ya sea por métodos gráficos ó analíticos; la matriz de puntos (*dot-plot*) de una secuencia puede evidenciar la baja complejidad de manera visual por medio de la saturación de puntos en una región de la matriz, lo que hace al análisis visual un instrumento importante en la determinación de secuencias simples. (Fig. 2).

a)



b)




Fig. 2. Representación visual de dos secuencias de aminoácidos, por medio de una matriz de puntos (*dot-plot*), para la determinación de secuencias simples, a) la secuencia SR40 al compararse contra ella misma, presenta segmentos con sesgos composicionales representados por la saturación de puntos y en b) la secuencia HI0115 al compararse contra ella misma, esta no presenta segmentos con sesgos composicionales.

La complejidad de una secuencia fue definida por Wootton y Federhen (1993) como el producto del número de secuencias posibles en un segmento n , por el inverso del logaritmo (base 20 ó 4, según el caso), de una ventana de tamaño L (ecuación 1). Esta ecuación puede ser utilizada para cuantificar la complejidad de una secuencia, dando una alternativa de análisis al método gráfico (*dot-plot*).

$$K_1 = \frac{1}{L} \log_{20} \left(\frac{L!}{\prod_{i=1}^{20} n_i!} \right)$$

Ecuación 1. Donde K_1 es el valor complejidad, n_i son los 20 aminoácidos ó los 4 nucleótidos de la secuencia y L es el número de secuencias probables (Wootton y Fedheren, 1993). (Apéndice I).

1.2 Genómica y filogenias universales.

El eminente desarrollo de las técnicas de secuenciación del material genético ha producido un importante acervo de información biológica, junto a este incremento de datos moleculares, el desarrollo de las ciencias de la informática ha permitido un fácil análisis de los mismos. Esto en conjunto, ha permitido plantear nuevas preguntas en el estudio de la Evolución, en especial en el análisis de genomas completos, disciplina que hoy se conoce como genómica, la cual ofrece nuevas perspectivas en análisis y caracterización de los mecanismos de expresión, modificación y evolución del genoma (Clark, 1994).

El análisis filogenético de las secuencias 16/18S rRNA no solamente permitió a Woese y Fox (1977) caracterizar a las arqueobacterias como una rama

monofilética claramente definida, sino que también mostró que todas las especies conocidas forman parte de un mismo árbol filogenético en el cual es posible distinguir otros dos linajes, formados por las eubacterias y eucariontes. Este árbol evolutivo sin raíz, que resultó de la comparación de las secuencias de genes ortólogos de rRNA, se trifurca a partir de un ancestro común. Dicha información llevo a uno de los planteamientos más importante de la biología contemporánea, la filogenia universal de los seres vivos en tres grandes grupos taxonómicos, los dominios: Arquea, bacteria y Eucaria (Woese *et al.*, 1990).

En la actualidad se cuenta con 20 genomas completos secuenciados provenientes de los tres dominios, **a) Bacteria:** *Haemophilus influenzae* (Fleischmann *et. al.*, 1995), *Mycoplasma genitalium* (Fraser *et. al.*, 1995), *Synechocystis* sp. (Kaneko *et. al.*, 1996), *Mycoplasma pneumoniae* (Himmelreich *et. al.*, 1996), *Helicobacter pylori* (Tomb *et. al.*, 1997), *Helicobacter pylori* (Alm *et al.*, 1999), *Escherichia coli* (Blattner *et. al.*, 1997), *Bacillus subtilis* (Kunst *et.al.*, 1997), *Borrelia burgdorferi* (Fraser *et al.*, 1997), *Aquifex aeolicus* (Deckert *et al.*, 1998), *Mycobacterium tuberculosis* (Cole *et al.*, 1998), *Treponema pallidum* (Fraser *et al.*, 1998), *Chlamydia trachomatis* (Stephens *et al.*, 1998), *Rickettsia prowazekii* (Andersson *et al.*, 1998); **b) Arquea:** *Methannococcus jannaschi* (Buit *et al.*, 1996), *Methanobacterium thermoautotrophicum* (Smith *et al.*, 1997), *Archaeoglobus fulgidus* (Klenk *et al.*, 1997), *Pyrococcus horikoshii* (Kawarabayasi *et al.*, 1998); y **c) Eucaria:** *Saccharomyces cerevisiae* (Goffeau *et al.*, 1997). y *Caenorhabditis elegans* (www.sanger.ac.uk/Projects/C_elegans/).

1.3 Planteamiento.

Uno de los principales desafíos en el estudio de la evolución temprana de la vida, es entender como se origina e incrementa el material genético y como este se vuelve fuente de variación para la evolución de las proteínas. La duplicación génica (parálloga), y la simbiosis son los principales mecanismos propuestos para solucionar estos problemas. Si bien, se ha comprobado el importante papel de estos fenómenos en la elongación del material genético (Horowitz, 1945; Waley, 1969), también es cierto que estos no resuelven completamente el problema.

En este trabajo se pretende caracterizar a las secuencias simples que se encuentran en regiones codificantes de los genomas completos, tratando de entender el papel que estas han jugado en la evolución de las proteínas. Si las secuencias simples están presentes en un alto porcentaje en las regiones codificantes del genoma y como estas son producidas principalmente por el patinaje de la polimerasa (*slippage-process*), es factible pensar que este fenómeno a tenido que ver directamente con el incremento de las proteínas, tanto en su número como en su tamaño y es posible que jugara un papel en la adquisición de nuevas funciones.



1.4 Objetivos

Objetivo general:

-Conocer el papel de las secuencias simples con baja complejidad de tres genomas microbianos completos (*Haemophilus influenzae*, *Methanococcus jannaschii*, *Saccharomyces cerevisiae*) en el origen y evolución de las proteínas.

Objetivos particulares:

-Conocer la frecuencia de secuencias simples (utilizando un método gráfico de matriz de puntos) en los genomas microbianos completos de *Haemophilus influenzae*, *Methanococcus jannaschii*, *Saccharomyces cerevisiae*.

-Definir la distribución funcional de las secuencias con baja complejidad en los tres genomas completos.

-Realizar un análisis de las secuencias simples encontradas en los tres genomas microbianos, para conocer la composición, distribución de cargas, distribución de otros aminoácidos tipo, estructuras repetidas, multipletes, periodicidad y espacialidad. Con el fin de caracterizar el fenómeno.

CUCBA



BIBLIOTECA CENTRAL

2. MATERIAL Y METODOS

Las secuencias de aminoácidos de los tres genomas microbianos (*Haemophilus influenzae*, *Methanococcus jannaschii*, *Saccharomyces cerevisiae*) se obtuvieron por medio del *anonymous* FTP del GenBank (disponible en <http://www.ncbi.nlm.nih.gov/>). Se realizó una comparación de cada una de las secuencias por medio de una matriz de puntos realizada con el programa Dot plot Coral Software PROGRAM V1.0 1989. El programa se instaló y corrió en una PC-pentium. Con este programa se realizó un análisis gráfico-visual de todas las secuencias de aminoácidos provenientes de los tres genomas microbianos, el programa permite comparar una secuencia contra ella misma mostrando en la pantalla una matriz de puntos con las intersecciones de los aminoácidos, si existe una repetición de aminoácidos en la secuencia, el resultado visual es representado por una saturación de puntos. Los cálculos del programa fueron realizados con una ventana mínima de cinco (por cada cinco aminoácidos relacionados se coloca un punto), representando secciones de baja complejidad. Solamente se tomaron en cuenta las secuencias simples con secciones de baja complejidad mayores al 20% del total de la secuencia.

Para conocer la distribución funcional de las secuencias simples, estas se agruparon de acuerdo a su actividad metabólica en siete grupos funcionales: I) Metabolismo de macromoléculas, II) Metabolismo intermediario, III) Biosíntesis de moléculas pequeñas, IV) Procesos celulares, V) Estructura celular, VI) Otras funciones (Riley, 1993), y VII) Hipotéticas ó de función desconocida, para ello se

realizo un programa en lenguaje shell-unix, el cual identifico a las secuencias, con base a una lista de palabras claves referentes a cada grupo (Apéndice II).

Para analizar las secuencias que presentan menor grado de complejidad, se utilizó el programa SEG (segment sequence (s) by local complexity), el cual analiza la composición de complejidad local dentro de la secuencia, este programa se utilizó con los parámetros: $L=30$, $K_1=2.6$ y $K_2=2.8$ (Wootton y Federhen, 1993), lo que permite identificar a las secuencias con una marcada baja complejidad (Apéndice III).

Las secuencias de aminoácidos de los tres genomas que resultaron del SEG, se analizaron con el programa SAPS (Statistical Analysis of Protein Sequences), el cual esta disponible en la página http://ulrec3.unil.ch/software/SAPS_form.html. Este programa analiza **a)** la composición de la secuencia la cual es evaluada al comparar cada aminoácido con el valor porcentual ya establecido que se tiene para cada aminoácido, si el valor se excede se representa con los signos (++) (+), si el valor es muy bajo se usan los signos (--) (-), **b)** la distribución de cargas es evaluada por grupos de 30 a 60 aminoácidos con segmentos cargados ya sean positivos, negativos y mezclados, **c)** la distribución de otros aminoácidos tipo se indica por segmentos de aminoácidos hidrofóbicos y de transmembrana, **d)** las estructuras repetidas son indicadas por dos alfabetos: los 20 aminoácidos y 11 letras del alfabeto las que indican segmentos de aminoácidos hidrofóbicos (LVIF), cargados (KR y ED), pequeños (AG), los aromáticos (YW), el grupo hidroxil (ST) y el grupo amido (NQ), **e)** multitiplotes de la secuencia son evaluados por los aminoácidos y las cargas, contando también altitiplotes, **f)** la periodicidad es identificada por periodos entre 1

y 10 aminoácidos, por las cargas y la hidrofobicidad, **g)** la espacialidad es evaluada por los 20 aminoácidos en cuanto a la significancia larga o corta, máxima o mínima espacialidad en la distribución de los aminoácidos. Para todos los análisis del programa SAPS, solo se tomaron en cuenta las secuencias en las cuales sus resultados sobrepasan el rango (Apéndice IV).

Los programas utilizados para los anteriores análisis se corrieron en una estación de trabajo SUN-SPARC 20 y SUN-Ultra 5.

Se anexa un diagrama de flujo, mostrando los la depuración que se realizo de las secuencias de aminoácidos provenientes de los tres genomas microbianos.

CUCBA



BIBLIOTECA CENTRAL

Diagrama de flujo.

Obtención de las secuencias de aminoácidos de los tres genomas microbianos *H. influenzae*, *M. jannaschii* y *S. cerevisiae* por *anonymous* FTP del Genbank (<http://www.ncbi.nlm.nih.gov/>)



Análisis gráfico (*dot-plot*) con el programa Sclone. de las secuencias provenientes de los tres genomas microbianos.
Secuencias seleccionadas 486



Distribución funcional de las secuencias simples de los tres genomas microbianos.
486 secuencias.



Análisis con el programa SEG utilizando los parámetros $L=30$, $K_1=2.6$, $K_2=2.8$ secuencias seleccionadas 86



Análisis con el programa SAPS de 86 secuencias (composición, distribución de cargas, distribución de otros aminoácidos tipo, estructuras repetidas, multipletes, periodicidad y espacialidad).

3. RESULTADOS

De las secuencias de aminoácidos analizadas por el método gráfico (*dot-plot*) provenientes de los genomas microbianos de *Haemophilus influenzae*, *Methanococcus jannaschii* y *Saccharomyces cerevisiae* se seleccionaron 486 que presentaban segmentos con baja complejidad mayores al 20% del tamaño de la secuencia (Cuadro 2), observando el mayor número de secuencias simples en el genoma eucarionte (*S. cerevisiae*), seguido de la arqueobacteria (*M. jannaschii*) y la bacteria (*H. influenzae*).

Cuadro 2. Secuencias simples de los tres genomas microbianos

Genoma	Secuencias codificantes	Secuencias simples	Porcentaje
<i>Haemophilus influenzae</i> ^B	1,709	57	3.33%
<i>Methanococcus jannaschii</i> ^A	1,738	90	5.17%
<i>Saccharomyces cerevisiae</i> ^E	5,885	339	5.77%

^B bacteria ^A arquea ^E eucaria

La distribución funcional de las 486 secuencias simples se realizó para cada genoma (Fig.3) con base en los siete grupos funcionales, obteniendo el siguiente acomodo:

Haemophilus influenzae

I Metabolismo de macromoléculas

- >HI0067 DNA mismatch repair protein (mutL) {*Escherichia coli*}
- >HI0216 type I restriction enzyme *ecokI* specificity protein (hsdS) {*Escherichia coli*}
- >HI0231 ATP-dependent RNA helicase (*deaD*) {*Escherichia coli*}
- >HI0397 exonuclease VII, large subunit (*xseA*) {*Escherichia coli*}
- >HI0422 ATP-dependent RNA helicase (*smB*) {*Escherichia coli*}
- >HI0641 ribosomal protein L7/L12 (*rpL7/L12*) {*Escherichia coli*}
- >HI0699 rotamase, peptidyl prolyl cis-trans isomerase (*slyD*) {*Escherichia coli*}
- >HI0990 Iga1 protease (*iga1*) {*Haemophilus influenzae*}
- >HI1056 type III restriction-modification ECOP15 enzyme (*mod*) {*Escherichia coli*}

- >HI0245 queuosine biosynthesis protein (queA) {*Escherichia coli*}
- >HI1283 transcription factor (nusA) {*Salmonella typhimurium*}
- >HI1284 initiation factor IF-2 (infB) {*Escherichia coli*}
- >HI0550 lipooligosaccharide biosynthesis protein {*Haemophilus influenzae*}

II Metabolismo intermediario

- >HI0061 recombination protein (rec2) {*Haemophilus influenzae*}
- >HI0220 aerobic respiration control sensor protein (arcB) {*Escherichia coli*}
- >HI0251 energy transducer (tonB) {*Haemophilus influenzae*}
- >HI0446 fructose-permease IIBC component (fruA) {*Escherichia coli*}
- >HI0448 fructose-permease IIA/FPR component (fruB) {*Escherichia coli*}
- >HI0916 export factor homolog (skp) *Pasteurella multocida*
- >HI0971 biotin carboxyl carrier protein (fabE) {*Escherichia coli*}
- >HI1232 dihydrolipoamide acetyltransferase (aceF) {*Escherichia coli*}
- >HI1545 C4-dicarboxylate transport protein {*Rhizobium leguminosarum*}

III Biosíntesis de moléculas pequeñas

- >HI0264 heme-hemopexin-binding protein (hxA) {*Haemophilus influenzae*}
- >HI0538 urease protein (ureE) {*Helicobacter pylori*}

IV Procesos celulares

- >HI0049 2-keto-3-deoxy-D-gluconate kinase (kdgK) {*Erwinia chrysanthemi*}
- >HI0664 transport ATP-binding protein (cydC) {*Escherichia coli*}
- >HI0712 transferrin-binding protein 1 (tbp1) {*Neisseria meningitidis*}
- >HI1339 embryonic abundant protein, group 3 {*Triticum aestivum*}
- >HI1706 high-affinity choline transport protein (betT) {*Escherichia coli*}
- >HI1374 cell division protein (mukB) {*Escherichia coli*}

V Estructura celular

- >HI0066 N-acetylmuramoyl-L-alanine amidase (amiB) {*Escherichia coli*}
- >HI0119 adhesin B precursor (fimA) {*Streptococcus parasanguis*}
- >HI0383 outer membrane integrity protein (tolA) {*Escherichia coli*}
- >HI0915 UDP-3-O-(R-3-hydroxymyristoyl)-glucosamine
- >HI1579 15 kDa peptidoglycan-associated lipoprotein (lpp) {*Haemophilus influenzae*}
- >HI1685 outer membrane integrity protein (tolA) {*Escherichia coli*}

VI Otras funciones

- >HI0861 virulence associated protein homolog (vacB) {*Escherichia coli*}
- >HI1238 heat shock protein (dnaJ) {*Escherichia coli*}

VII hipotéticas y función desconocida

- >HI0147 hypothetical protein (SP:P37675) {*Escherichia coli*}
- >HI0259 hypothetical protein (GB:X73124_13) {*Bacillus subtilis*}
- >HI0271 hypothetical protein (SP:P31680) {*Escherichia coli*}
- >HI0519 hypothetical protein (SP:P33024) {*Escherichia coli*}
- >HI0526
- >HI0594
- >HI0662
- >HI0696 hypothetical protein (GB:U14003_133) {*Escherichia coli*}
- >HI0700 hypothetical protein (GB:U14003_167) {*Escherichia coli*}
- >HI0756 hypothetical protein (SP:P37690) {*Escherichia coli*}

- >HI1053 hypothetical protein (GB:M66060_5) {Alcaligenes eutrophus}
- >HI1058
- >HI1404
- >HI1495
- >HI1514
- >HI1517
- >HI1566
- >HI1601
- >HI1718

CUCBA



BIBLIOTECA CENTRAL

Methanococcus jannaschii

I Metabolismo de macromoléculas

- >MJ0124 type Y restriction enzyme
- >MJ0262 putative translation factor, FUN 12/biF-2 family o PIR:S48519
- >MJ0291 signal recognition particle protein EGAD:6866
- >MJ0462 ribosomal protein L29 o SP:P22665
- >MJ0487 phenylalanyl-tRNA synthase, subunit alpha o SP:P15625
- >MJ0508 ribosomal protein L12 o SP:P10623
- >MJ0510 ribosomal protein L1 o SP:P15824
- >MJ0564 alanyl-tRNA synthase (ala RS) o SP:P43815
- >MJ0591 proteasome, subunit alpha o GI:1002686
- >MJ0782 transcription initiation factor IIB PIR:S34116
- >MJ0882 ATPase, vanadate-sensitive o PIR:A38542
- >MJ1042 DNA-dependent RNA polymerase, subunit A' o SP:P41556
- >MJ1176 ATP-dependent 26S protease regulatory subunit 4 EGAD:827
- >MJ1214 type I restriction enzyme EGAD:28293
- >MJ1238 prolyl-tRNA synthetase SP:P07814
- >MJ1263 methionyl-tRNA synthetase EGAD:28284
- >MJ1422 replication factor CEGAD:237
- >MJ1505 putative ATP-dependent RNA helicase, eIF-4A family SP:P40562
- >MJ1512 reverse gyrase SP:Q08582

II Metabolismo intermediario

- >MJ0152 carbon monoxide dehydrogenase, alpha subunit o SP:P27988
- >MJ0156 carbon monoxide dehydrogenase, iron-sulfur subunit o SP:P27273
- >MJ0221 ATP synthase, subunit K o SP:P43457
- >MJ0222 ATP synthase, subunit Y o SP:P43439
- >MJ0514 polyferredoxin o PIR:S24802
- >MJ0542 phosphoenolpyruvate synthetase o SP:P42850
- >MJ0829 peptide chain release factor
- >MJ0832 anaerobic ribonucleoside-triphosphate reductase o SP:P28903
- >MJ0860 bifunctional short chain isoprenyl diphosphate synthase o P:S75695_1
- >MJ1231 oxaloacetate decarboxylase, alpha subunit SP:Q03030
- >MJ1303 polyferredoxin PIR:G30315
- >MJ1408 GTP-binding protein, GTP1/OBG-family GP:U43281_15

III Biosíntesis de moléculas pequeñas

- >MJ1057 glycosyl transferase GP:U14554_5
- >MJ1362 NADH dehydrogenase, subunit 1 GP:L29771_1
- >MJ1420 glutamine-fructose-6-phosphate transaminase SP:P17169

>MJ1269 branched-chain amino acid transport protein livH SP:P08340

IV Procesos celulares

>MJ1156 cell division control protein CDC48 SP:P25694

>MJ1275 NA(+)/H(+) antiporter SP:P26235

V Estructura celular

VI Otras funciones

>MJ0718 chromate resistance protein A o SP:17551

>MJ1166 tungsten formylmethanofuran dehydrogenase, subunit C o GP:X87970_2

>MJ1171 tungsten formylmethanofuran dehydrogenase, subunit C o GP:X87970_6

>MJECL23

>MJECL28

VII hipotéticas y función desconocida

>MJ0223

>MJ0233

>MJ0280

>MJ0345

>MJ0392 hypothetical protein (GP:D64006_95) o GP:D64006_95

>MJ0401

>MJ0449 hypothetical protein (SP:P46348) o SP:P46348

>MJ0634

>MJ0647

>MJ0650

>MJ0652

>MJ0682

>MJ0690

>MJ0694

>MJ0702

>MJ0704

>MJ0748

>MJ0770

>MJ0835

>MJ0875

>MJ0987

>MJ1007

>MJ1017

>MJ1049

>MJ1053

>MJ1134

>MJ1158

>MJ1185

>MJ1189

>MJ1213

>MJ1221

>MJ1225 hypothetical protein (SP:P15889) SP:P15889

>MJ1254

>MJ1280

>MJ1281

CUCBA



BIBLIOTECA CENTRAL

CUCBA



BIBLIOTECA CENTRAL

>MJ1290
>MJ1293
>MJ1321
>MJ1322
>MJ1396
>MJ1401
>MJ1412
>MJ1519
>MJ1525
>MJ1556
>MJ1564
>MJ1666
>MJ1674

Saccharomyces cerevisiae

I Metabolismo de macromoléculas

>SW ADR6_YEAST P09547 transcription regulatory protein
>GP-780798 (U24143) ribosomal protein S12
>GP-D1003672 (D14080) elongation factor-1 beta
>PIR:S13653 putative atp-dependent rna helicase
>SW-NSR1_YEAST P27476 nuclear localization sequence binding protein
>SW-SPT8_YEAST P38915 transcription factor spt8
>GP-172076 (M88605) contains Cys-4 zinc-finger, resembles erythroid transcription factor GATA-1
>GP-4358 (X57160) RNA1 protein
>SW-T2EA_YEAST P36100 transcription factor a large subunit
>SW-TBP7_YEAST P40340 tat-binding homolog 7
>SW-TIF3_YEAST P34167 translation initiation factor
>GP-967213 (U28158) Protein involved in decay of mRNA containing nonsense codons
>PIR:S48440 pab-dependent poly(a)-specific ribonuclease (EC 3.1.13.4)
>SW-UME6_YEAST P39001 transcriptional regulator ume6
>GP-641352 (A21198) DNA sequence
>GP-D1007731 (D37935) RNA binding protein
>PIR:A34599 DNA-binding protein
>PIR:S55102 high copy DNA polymerase
>SW-SPT5_YEAST P27692 transcription initiation protein
>SW-TIF3_YEAST P34167 translation initiation
>SW-PRCG_YEAST P22141 proteasome component (ec 3.4.99.46)
>GP-172096 (M90688) polyA nuclease
>GP-530998 (L34569) proline rotamase
>PIR:S50615 U6 snRNA-associated protein USS1
>SW-ERF2_YEAST P05453 eukaryotic peptide chain release factor gtp-binding subunit (erf2)
>SW-FKB3_YEAST (peptidyl-prolyl cis-trans isomerase) (ec 5.2.1.8) (proline rotamase)
>SW-YIN0_YEAST transcriptional regulatory protein in fkh1-sth1
>GP-295671 selected as a weak suppressor of a mutant of the subunit AC40 of DNA dependant RNA polymerase I and III
>PIR:S48244 nonsense-mediated mrna decay protein 2 (up-frameshift suppressor 2)

II Metabolismo intermediario

>GP-E11351 (X01474) polyubiquitin precursor fragment

>PIR-A41035 chitinase (EC 3.2.1.14)
 >SW-CHIT_YEAST P29029 endochitinase precursor (ec 3.2.1.14)
 >PIR:A34796 kinesin-like protein kar3 (nuclear fusion protein)
 >PIR:S45578 (increasing suppression factor 1)
 >GP-706835 (X84162) deubiquinating enzyme
 >PIR-D29456 polyubiquitin 5 - yeast
 >PIR:S39110 valosin-containing protein homolog AFG2 - yeast
 >SW-CG12_YEAST P20438 g1/s-specific cyclin cln2
 >SW-HR25_YEAST P29295 casein kinase i homolog hrr25
 >SW-KAI1_YEAST P41944 protein kinase a interference protein
 >SW-KIP1_YEAST P28742 kinesin-like protein kip1
 >SW-SFP1_YEAST P32432 zinc finger protein sfp1
 >SW-SLT2_YEAST Q00772 mitogen-activated protein kinase slt2/mpk1 (ec 2.7.1.-)
 >SW-SR40_YEAST P32583 yeast). supressor protein srp40
 >SW-SR54_YEAST P20424 signal recognition particle 54 kd protein
 >GP-171945 (M55016) mating factor alpha
 >SW-MFA3_YEAST P01149 mating factor alpha-1 precursor
 >SW-MID2_YEAST P36027 mating process protein mid2 (serine-rich protein sms1)
 >SW-UCRH_YEAST P00127 yeast). ubiquinol-cytochrome c reductase complex
 >SW-MDJ1_YEAST P35191 mdj1 protein precursor
 >GP-433624 (X60327) casein kinase-1
 >SW-PIR1_YEAST Q03178 pir1 protein precursor
 >SW-SED1_YEAST Q01589 protein precursor
 >S-W-PIR3_YEAST Q03180 pir3 protein precursor
 >SW-BEM2_YEAST P39960 gtpase activating protein Bem2p: bud-emergence protein
 >GP-173134 (M63498) regulatory protein

III Biosíntesis de moléculas pequeñas

>GP-396560 (X74428) serine-rich protein
 >GP-854568 (X87611) adenylate cyclase
 >SW-NAB2_YEAST P32505 nuclear polyadenylated rna-binding protein nab2
 >SW-ABP1_YEAST P15891 actin binding protein.
 >PIR-DNBYP A polyadenylate-binding protein - yeast
 >SW-PGD1_YEAST P40356 yeast). poly-glutamine domain protein
 >SW-PPZ1_YEAST P26570 serine/threonine protein phosphatase (ec 3.1.3.16)
 >SW-PPZ2_YEAST P33329 serine/threonine protein phosphatase (ec 3.1.3.16)
 >GP-171044 (M28164) alpha-agglutinin
 >GP-633630 (Z47746) probable zinc finger protein
 >GP-854474 (Z49810) serine/threonine specific protein phosphatase
 >GP-927693 (U33007) serine/threonine protein phosphatase
 >SW-KFD3_YEAST P43565 serine/threonine-protein kinase
 >SW-KKR1_YEAST P36003 serine/threonine-protein kinase
 >SW-KNQ1_YEAST P53894 serine/threonine-protein kinase
 >PIR-S62057 proline-rich protein LAS17 - yeast
 >GP-172586 (L04655) serine/threonine protein kinase
 >SW-AGA1_YEAST P32323 a-agglutinin attachment subunit precursor
 >PIR-ALBYG glucan 1,4-alpha-glucosidase (EC 3.2.1.3)
 >SW-AMYH_YEAST P08640 (glucan 1,4-alpha- glucosidase)
 >SW-BCK1_YEAST Q01389 serine/threonine protein kinase
 >SW-NRK1_YEAST P38692 serine/threonine-protein kinase nrk1 (ec 2.7.1.-)
 >SW-SSN6_YEAST P14922 glucose repression mediator protein

- >SW-ST20_YEAST Q03497 serine/threonine-protein kinase ste20 (ec 2.7.1.-)
- >STT4_YEAST P37297 phosphatidylinositol 4-kinase stt4 (ec 2.7.1.67)
- >PIR-DNBYPY polyadenylate-binding protein

IV Procesos celulares

- >SW-USO1_YEAST P25386 intracellular protein transport protein
- >SW-WEB1_YEAST P38968 protein transport protein sec31
- >PIR:S70292 FUN12 protein transport protein
- >GP-4018 myosin heavy chain type II
- >GP-4047 (X56084) nitrogen permease reactivator protein
- >SW-CC24_YEAST P11433 cell division control protein
- >PIR:S22853 datin oligo(a)/oligo(t)-binding
- >SW-KKS1_YEAST P20486 (cell division control protein cks1)
- >SW-CTR1_YEAST P49573 copper transport protein ctr1 (copper transporter 1)

V Estructura celular

- >GP-3730 (X53424) glycolipid-anchored surface protein
- >GP-1230689 (U51033) Weak similarity to Cell surface glycoprotein precursor of Halobacterium Halobium
- >SW-CWP1_YEAST P28319 cell wall protein cwp1 precursor
- >SW-EM70_YEAST P32802 endosomal p24a protein precursor (70 kd endomembrane protein) (pheromone alpha-factor transporter)
- >GP-172790 (M21129) omnipotent suppressor
- >GP-2258166 (U20618) regulatory protein of adenylate cyclase
- >GP-311109 (L16900) intrastrand crosslink recognition protein
- >PIR-S77699 inner cell wall mannoprotein
- >SW-IXR1_YEAST P33417 intrastrand crosslink recognition protein (structure-specific recognition protein)
- >SW-SLA1_YEAST P32790 cytoskeleton assembly control protein sla1
- >SW-PUB1_YEAST P32588 nuclear and cytoplasmic polyadenylated rna-binding protein pub1
- >GP-4076 (Z15036) nuclear pore complex protein
- >GP-496731 (Z32672) nucleoporin
- >GP-642341 (X83099) GLFG motif nucleoporin
- >SW-N145_YEAST P49687 nucleoporin
- >SW-NU49_YEAST Q02199 nucleoporin
- >SW-NU57_YEAST P48837 nucleoporin
- >SW-NOP3_YEAST Q01560 nucleolar protein 3 (mitochondrial targeting supressor 1 protein)
- >SW-N159_YEAST P40477 nucleoporin
- >PIR: nucleoskeletal-like protein
- >PIR:S52700 nuclear pore protein
- >PIR:A35622 nuclear pore protein

VI Otras funciones

- >GP-871535 (X87806) verprolin
- >GP-415259 (L15626) dynein
- >PIR:S25194 zuotin – yeast
- >GP-D1020704 (AB003521) flocculin
- >GP-E304948 (A39780) Flocculation protein
- >SW-R167_YEAST P39743 reduced viability upon starvation protein 167.

- >SW-HKR1_YEAST P41809 hansenula mrakii killer toxin-resistant protein 1 precursor
- >SW-HS82_YEAST P02829 heat shock protein hsp82
- >SW-DR48_YEAST P18899 ddr48 stress protein (dna damage-responsive protein 48) (flocculent specific protein)
- >GP-E304948 (A39780) Flocculation protein
- >SW-FLO1_YEAST P32768 flocculation protein flo1 precursor
- >SW-SFL1_YEAST P20134 flocculation suppression protein
- >PIR: (multicopy suppression of a budding defect 2)
- >SW-TIR1_YEAST P10863 cold shock induced protein tir1 precursor
- >SW-TIR2_YEAST P33890 cold shock induced protein tir2 precursor
- >GP-171388 (M36110) DDR48 stress protein
- >SW-CG12_YEAST P20438 g1/s-specific cyclin cln2
- >GP-42684 (S42682) 46-kDa negative regulator of the Ras-cyclic AMP pathway=RP11
- >GP-472525 (L31766) synthetic lethal 39
- >SW-ALK1_YEAST P43633 dna damage-responsive protein alk1
- >SW-H150_YEAST P32478 150 kd heat shock glycoprotein precursor
- >GP-854443 (Z49808) Ddr48p FSP=flocculent specific protein
- >SW-DR48_YEAST P18899 ddr48 stress protein (dna damage-responsive protein 48) (ddrp 48) (flocculent specific protein)

VII hipotéticas y función desconocida

- >SW-GTS1_YEAST P40956 gts1 protein
- >PIR-S33>SW-IFH1_YEAST P39520 ifh1 protein (rrp3 protein)651 protein - yeast
- >PIR:S05807 SAN1 protein - yeast
- >PIR:S62061 SCD5 protein - yeast
- >SW-SED4_YEAST P25365 sed4 protein
- >GP-832919 (X71664) But2
- >SW-YKU1_YEAST (Z28201) ORF YKL201c MH1
- >GP-809098 (Z49260) Bul1p
- >GP-927738 (U33050) Tom1p; CAI: 0.16
- >GP-984964 (U20237) Sik1p
- >GP-171536 (M16717) open reading frame
- >PIR:S54016 SOK2 protein - yeast
- >GP-2340996 (U21094) Ylr437cp
- >GP-E251944 (Z74917) ORF YOR009w
- >GP-3413 (X16385) Baf1 protein (AA 1-731) unknown
- >GP-3781 (X03245) ded1 unknown
- >GP-D1002336 (D11088) Cks1 protein
- >GP-D1002337 (D11088) Cks1.2 protein
- >GP-D1002338 (D11088) Cks1.3 protein
- >SW-SOK1_YEAST P40317 sok1 protein
- >SW-SP41_YEAST P38904 yeast spp41 protein
- >PIR:S61992 SLG1 protein - yeast
- >GP-809086 (Z49260) unknown
- >GP-817890 (Z49703) unknown
- >GP-825569 (Z49705) unknown
- >GP-E221836 (Z69382)) unknown
- >GP-E318906 (Z28080) ORF YKL081w
- >GP-E183305 (Z49809) unknown
- >GP-E242679 (X97751) unknown
- >GP-E243293 (Z72598) ORF YGL076c


CUCBA



BIBLIOTECA CENTRAL

- >GP-E245463 (Z73136) ORF YLL031c
- >GP-E245807 (Z73286) ORF YLR114c
- >GP-E246768 (Z73616) hypothetical 119.5 kDa protein unknown
- >SW-YB59_YEAST P38311 hypothetical 12.1 kd in dur1,2-ngr1 intergenic region
- >GP-E252085 (Z75128) ORF YOR220w
- >GP-E252143 (Z75217) ORF YOR310c
- >GP-E252970 (Z74053) ORF YDL005c unknown
- >GP-E253063 (Z74201) ORF YDL153c
- >GP-E308403 (Z74105) ORF YDL058w
- >GP-E312758 (Z72557) ORF YGL188c
- >GP-171485 (L07289) gene product
- >GP-896461 (U31331) Tel1p
- >GP-E312887 (Z72946) ORF YGR159c
- >GP-E322120 (Z73259) ORF YLR086w
- >GP-E332821 (Z73562) ORF YPL207w
- >SW-GDS1_YEAST P41913 gds1 protein - yeast
- >GP-S47695_1 (S47695) YBL03-15B
- >SW-SCJ1_YEAST P25303 scj1 protein. - yeast unknown
- >SW-SIS1_YEAST P25294 sis1 protein unknown
- >SW-YB59_YEAST P38311 hypothetical 12.1 kd in dur1,2-ngr1 intergenic region
- >SW-YBC9_YEAST P38201 hypothetical 42.6 kd in aac2-rpl19 intergenic region
- >SW-YCC8_YEAST P25367 hypothetical 42.6 kd in bik1-fus1 intergenic region
- >SW-YEA7_YEAST P40002 hypothetical 72.5 kd in gcn4-wbp1 intergenic region
- >SW-YEN7_YEAST P39955 hypothetical 100.3 kd in mei4-caj1 intergenic region
- >SW-YFB0_YEAST P43582 hypothetical 22.7 kd in aua1-cdc4 intergenic region
- >SW-YFC3_YEAST P43573 hypothetical 91.4 kd in ste2-frs2 intergenic region
- >SW-YG1F_YEAST P53214 hypothetical 57.5 kd in vma7-rps31a intergenic region
- >GP-2340996 (U21094) Ylr437
- >SW-MTH1_YEAST P35198 MTH1 protein - yeast
- >GP-4814 gene product
- >GP-E190152 (X89715) gene product
- > PIR:A36426 SPA2 protein - yeast
- >GP-3712 (Y00829) gene product
- >GP-914986 (U32445) gene product
- >GP-861110 (X87672) gene product
- >GP-567922 (L36903) varl gene product
- >GP-4550 gjl4550 (X66278) gene product
- >GP-496695 (X79489) CDC27 D-618 protein
- >GP-559524 (X78344) CAT8
- >SW-YHT1_YEAST P38835 hypothetical 95.1 kd in act5-yck1 intergenic region
- >SW-YHV8_YEAST P38853 hypothetical 131.1 kd in rec104-sol3 intergenic region
- >SW-YIM9_YEAST P40468 hypothetical 269.9 kd in fkh1-sth1 intergenic region
- >SW-YJ9P_YEAST P47179 hypothetical 118.4 kd in rps7b-dal5 intergenic region
- >SW-YJU7_YEAST P39526 hypothetical 229.9 kd in nuc1-prp21 intergenic region
- >SW-YK22_YEAST P36135 hypothetical 46.9 kd in gap1-nap1 intergenic region
- >SW-YK25_YEAST P36138 hypothetical 21.1 kd in gap1-nap1 intergenic region
- >SW-YKR2_YEAST P36049 hypothetical 49.7 kd protein in gin2-ste3 intergenic region
- >SW-YNF8_YEAST P53947 hypothetical 35.0 kd in nop2-omp2 intergenic region
- >SW-YTP2_YEAST P38429 hypothetical 22.9 kd protein in tps3 5' region (orf2)
- >GP-1072409 (Z54141) unknown
- >GP-1002516 (U27358) Hgh1p

CUCBA



BIBLIOTECA CENTRAL

>GP-171374 (M60415) DAL81
 >GP-172526 (M16165) S1 protein
 >GP-2264354 (U22383) Ylr466wp
 >GP-2340034 (U19028) Ylr338wp
 >GP-343949 (J01525) var1(40.0)
 >GP-544510 (U14913) Ylr194cp
 >GP-587539 (Z46373) unknown
 >GP-625104 (U19729) unknown
 >GP-663232 (Z48148) hypothetical 137.7 kD protein in subtelomeric Y' repeat region
 >GP-677198 (L03188)
 >GP-78626 (S78624) YCR592
 >SW-N100_YEAST Q02629 unknown
 >GP-806319 (M22580) unknown protein
 >GP-854468 (Z49809) unknown
 >GP-854597 (X87611) ORF YJR83
 >GP-927801 (U33057) Ydr534cp
 >GP-971261 (U34775) Yer190wp
 >GP-984176 (Z54139) unknown
 >SW-BMH2_YEAST P34730 unknown
 >GP-E190749 (Z50178) unknown
 >GP-E236693 (Z71255) unknown
 >GP-E236826 (Z71255) unknown
 >GP-E245755 (Z73145) ORF YLL040c
 >GP-E245920 (Z73256) ORF YLR084c
 >GP-E247047 (Z73514) ORF YPL158c
 >GP-E247049 (Z73519) ORF YPL163c
 >GP-E251848 (Z74772) ORF YOL030w unknown
 >GP-E251930 (Z74897) ORF YOL155c
 >GP-E252202 (Z75291) ORF YOR383c
 >GP-E252294 (Z74847) ORF YOL105c
 >GP-E252336 (Z74961) ORF YOR053w
 >GP-E252449 (Z75290) ORF YOR382w
 >GP-E252988 (Z74083) ORF YDL035c unknown
 >GP-E252991 (Z74087) ORF unknown
 >GP-E304627 (Z35789) ORF YBL029w
 >GP-E304709 (Z35948) ORF YBR078w
 >GP-E312776 (Z72946) ORF YGR160w
 >GP-E312885 (Z72905) ORF YGR119c
 >GP-E312896 (Z72902) ORF YGR116w
 >PIR-S54624 ROD1 protein - yeast
 >PIR-S61046 ARP1 protein - yeast
 >PIR-S61977 RLM1 protein - yeast unknown
 >SW-ST50_YEAST P25344 YCL032w
 >SW-YAF3_YEAST P39719 hypothetical 87.5 kd in acs1-gcv3 intergenic region
 >SW-YBF1_YEAST P34217 hypothetical 73.8 kd in shp1-sec17 intergenic region
 >SW-YBF3_YEAST P38190 very hypothetical 13.2 kd in shp1-sec17 intergenic region
 >SW-YBV8_YEAST P38266 hypothetical 92.8 kd in ymc2-cmd1 intergenic region
 >SW-YFG7_YEAST P43537 hypothetical 16.5 kd protein in thi5 5' region unknown
 >SW-YG42_YEAST P53297 hypothetical 78.8 kd protein in erg1-rnr4 intergenic region
 >SW-YG46_YEAST P53301 hypothetical 52.8 kd in bub1-hip1 intergenic region
 >SW-YG5W_YEAST P53335 hypothetical 31.3 kd in taf145-yor1 intergenic region

CUCBA



BIBLIOTECA CENTRAL

>SW-YKK5_YEAST P34250 hypothetical 125.6 kd in *aat1-gfa1* intergenic region
 >SW-YGG7_YEAST P53164 hypothetical 43.5 kd in *rpb9-alg2* intergenic region
 >SW-YHU3_YEAST P38844 hypothetical 33.4 kd in *rpl44-dcd1* intergenic region
 >SW-YIM3_YEAST P40472 hypothetical 48.1 kd protein in *kgd1-rpi1* intergenic region
 >SW-YIO9_YEAST P40457 hypothetical 195.1 kd in *dna43-ubi1* intergenic region
 >SW-YIQ9_YEAST P40442 hypothetical 99.7 kd in *suc2* 5' region precursor unknown
 >SW-YIR7_YEAST P40434 hypothetical 197.5 kd protein in *suc2* 5' region. unknown
 >SW-YJH4_YEAST P47037 hypothetical 141.3 kd in *scp160-mrpl8* intergenic region
 >SW-YJH6_YEAST P47035 hypothetical 128.5 kd in *scp160-mrpl8* intergenic region
 >SW-YJH8_YEAST P47033 hypothetical 89.2 kd in *scp160-mrpl8* intergenic region
 >SW-YJQ0_YEAST P46999 hypothetical 19.0 kd in *tpk1-far1* intergenic region
 >SW-YJZ3_YEAST P47094 hypothetical 15.3 kd in *mer2-cpr7* intergenic region
 >PIR:S38082 pathogenesis-related protein hypothetical 33.8 kd intergenic region
 >SW-YN23_YEAST P53832 hypothetical 52.3 kd in *mrpl10-erg24* intergenic region
 >SW-YNT0_YEAST P53872 hypothetical 22.0 kd in *chs1-srp1* intergenic region
 >SW-YNW8_YEAST P53862 hypothetical 28.6 kd in *ure2-ssu72* intergenic region
 >GP-1165299 (U43834) Ydr544cp
 >GP-544503 (U14913) Ylr206wp
 >GP-694125 (L28920) cloning and analysis of the yeast
 >GP-728653 (Z48613) unknown
 >GP-915002 (U32517) Ydr326cp
 >GP-927751 (U33050) Ydr474cp; CAI: 0.12
 >SW-AS10_YEAST P48361 ask10 protein
 >GP-E217728 (X94335) YOR3162c
 >GP-E223636 (Z46727) Sac7p
 >GP-E239064 (X96876) putative ORF
 >GP-E245461 (Z73133) ORF YLL028w
 >GP-E245541 (Z73258) ORF YLR086w
 >GP-E245804 (Z73278) ORF YLR106c
 >GP-E245919 (Z73172) ORF YLL067c
 >GP-E247083 (Z73541) ORF YPR204w
 >GP-E251834 (Z74749) ORF YOL007c
 >GP-E251917 (Z74876) ORF YOL133w
 >GP-E252273 (Z74793) ORF YOL051w
 >GP-E252431 (Z75217) ORF YOR309c
 >GP-E252990 (Z74085) ORF YDL037c unknown
 >GP-E253056 (Z74188) ORF YDL140c
 >SW-EGT2_YEAST P42835 10/96 ORF YNL327w
 >PIR-S37788 PIR3 protein - yeast unknown
 >SW-UTR2_YEAST P32623 *utr2* protein (unknown transcript 2 protein)
 >SW-YAG3_YEAST P39712 hypothetical 138.1 kd in *flo9-gdh3* intergenic precursor
 >SW-YBI1_YEAST P38180 hypothetical 40.8 kd in *rhk1-pet112* intergenic region
 >SW-YBM6_YEAST P38216 hypothetical 14.6 kd protein in *ttp1-gal7* intergenic region
 >SW-YBY0_YEAST P38272 hypothetical 47.4 kd in *vma2-cks1* intergenic region
 >SW-YCS2_YEAST P25356 hypothetical 251.0 kd in *cry1-gns1* intergenic region
 >SW-YCX9_YEAST P25653 hypothetical 166.0 kd protein in *abp1* 3' region
 >SW-YEW2_YEAST P32634 hypothetical 195.4 kd in *rps26b-glc7* intergenic region
 >SW-YEW2_YEAST P32634 hypothetical 195.4 kd pin *rps26b-glc7* intergenic region
 >SW-YG31_YEAST P53269 hypothetical 27.2 kd protein in *clb6-spt6* intergenic region
 >SW-YG3R_YEAST P53288 hypothetical 22.2 kd in *nsr1-tif4631* intergenic region
 >SW-YG4G_YEAST P42939 hypothetical 12.0 kd in *ade3-ser2* intergenic region

CUCBA



BIBLIOTECA CENTRAL



>SW-YG5V_YEAST P53334 hypothetical 40.2 kd in taf145-yor1 intergenic region
 >SW-YHC8_YEAST P38739 hypothetical 63.8 kd in gut1-rim1 intergenic region
 >SW-YHF0_YEAST P38721 hypothetical 79.0 kd in cbp2 5'region
 >SW-YJP9_YEAST P47000 hypothetical 30.8 kd in tpk1-far1 intergenic region
 >SW-YK82_YEAST P36170 hypothetical 122.2 kd in sir1 3'region precursor
 >SW-YKB4_YEAST P34241 hypothetical 203.3 kd in put3-cce1 intergenic region
 >SW-YKF4_YEAST P35732 hypothetical 84.0 kd in nup120-cse4 intergenic region
 >SW-YKS7_YEAST P34231 hypothetical 81.0 kd in pat1-mtr2 intergenic region
 >SW-YKU2_YEAST P36042 hypothetical 21.2 kd in tor2-pas1 intergenic region
 >SW-YN48_YEAST P42846 hypothetical 68.7 kd in stb1-mck1 intergenic region
 >SW-YN96_YEAST P53753 hypothetical 121.1 kd in bio3-hxt17 intergenic region
 >SW-YNJ1_YEAST P53935 hypothetical 141.5 kd in ypt53-rho2 intergenic region
 >SW-YNR6_YEAST P53882 hypothetical 67.4 kd in rps3-psd1 intergenic region
 >SW-YSY2_YEAST P24089 hypothetical 137.7 kd in subtelomeric y' repeat region of chr
 xv
 >GP-E223720 (Z68194) unknown
 >SW-PC11_YEAST P39081 pcf11 protein unknown
 >PIR-S30839 UTR2 protein - yeast
 >PIR-S67070 GAC1 protein - yeast
 >SW-YHT1_YEAST P38835 hypothetical 95.1 kd in act5-yck1 intergenic region 1
 >SW-YIB1_YEAST P40552 hypothetical 26.3 kd in pdr11-faa3 intergenic region
 >SW-YN7_YEAST P53968 hypothetical 76.3 kd zinc finger in hhf2-ume3 intergenic
 region

En la (Fig. 4) se muestra una comparación porcentual de los grupos funcionales con respecto a los tres genomas microbianos.


CUCBA



BIBLIOTECA CENTRAL

Haemophilus influenzae*Methanococcus jannaschii*

CUUCBA

*Saccharomyces cerevisiae*

BIBLIOTECA CENTRAL

Fig. 3. Distribución porcentual de secuencias simples para cada genoma de acuerdo a su función metabólica: I Metabolismo de macromoléculas, II Metabolismo Intermediario, III Biosíntesis de moléculas pequeñas, IV Procesos celulares, V Estructura celular, VI Otras funciones, VII Hipotéticas y función desconocida.




Fig. 4. Agrupamiento de la distribución funcional de los tres genomas microbianos. I. Metabolismo de macromoléculas, II. Metabolismo intermediario, III. Biosíntesis de moléculas pequeñas, IV. Procesos celulares, V. Estructura celular, VI. Otras funciones, VII Hipotéticas y de función desconocida.


Con el fin de obtener solamente secuencias con una marcada baja complejidad para los tres genomas, se realizó una selección posterior de todas aquellas secuencias que tuvieran un valor K de 2.6 a 2.8 y una ventana mayor a 30 con el programa SEG, dando como resultado un total de 86 secuencias simples con baja complejidad; para *H. influenzae* se tienen 13 secuencias, en *M. jannaschii* 12 y en *S. cerevisiae* 61 secuencias simples.

El método cuantitativo de SEG tanto como el análisis gráfico (*dot-plot*) muestran regiones amplias con muy baja complejidad en las 86 secuencias analizadas de los tres genomas microbianos en la (Fig. 5) se muestran solamente algunas de las secuencias con su respectiva matriz de puntos, las restantes están en el (Apéndice V).

CUCBA



BIBLIOTECA CENTRAL




>SW-DR48_YEAST SW:DR48_YEAST P18899 saccharomyces cerevisiae (baker's yeast). ddr48 stress protein (dna damage-responsive protein 48) (ddrp 48) (yp 75) (flocculent specific protein). 10/96
 GLFDKVKQFANSNNNNDSGNNNQGDYVTKAENMIGEDRVNQFKSKI GEDRFDKMESKVR
 QQFSNTSINDNDSNNNDSYGSNNNDSYGSNNNDSYGSNNNDSYGSNNNDSYGSNNDDSYG
 SSNKKKSSYGSNNDDSYGSNNNDSYGSNNNDSYGSNNNDSYGSNNDDSYGSNNKKNKSSY
 GSNDDSYGSNNDDSYGSNNKKKSSYGSNNNDSYGSNNDDSYGSNNNDSYGSNNDDSYGS
 SNKKKSSYGSNNDDSYGSNNNDSYGSNNDDSYGSNNKKNKSSYGSNNDDSYGSNNDDSYGS
 YGSNNKKKSSYGSNNDDSYGSNNDDSYGSNNKKKSSYGSNNDDSYGSNNDDSYGSNNKKK
 SSYGSNNDDSYGSNNNDSYGSNNDDSYGSNNRKNKSYGSNNYGSNNDDSYGSNNRGG
 NQYGGDDDY

CUCBA



BIBLIOTECA CENTRAL




>SW-CHIT_YEAST SW:CHIT_YEAST P29029 saccharomyces cerevisiae (baker's yeast). endochitinase precursor (ec 3.2.1.14). 10/96; gi1596043 (U17243)
Endochitinase 2 [Saccharomyces cerevisiae]
MSLLYIILLFTQFLLLPTDAFDRSANTNIAVYWGQNSAGTQESLATYCESSDADIFLLSF
LNQFPFLGLNFANACSDTFS DGLLHCTQIAEDIETPCQSLGKKVLLSLGGASGSYLFSDDS
QAETFAQTLNDDTFEGEGTGASERPDSAVVDGFDFDIENNNEVGYALATKLRTLFAEGTK
QYYLSAAPQCYPFDASVGDLENADIDFAFIQFYNNYCSVSGQFNWDTWLTYAQTVSPNK
NIKFLGLPGSASAAGSGYISDTSLLESTIADIASSSSFGGIALWDASQAFSNELNGEPEY
VEILKNLLTSASQTATTTVATSKTSAASTSSASTSSASTSQKTTQSTTSTQSKSKVTL
PTASSAIKTSITQTTKTLTSSSTKTKSSLGTTTTESTLNSVAICTSMKTTLSSQITSAALVT
PQTTTTTIVSSAPIQTAITSTLSPATKSSSVVSLQTATTSTLSPPTTSTSSGTSSTSSGTS
SDSTARTLAKELNAQYAAGKLNKSTCTEGELIACSADGKFAVCDHSAWVMECASGTTTCY
AYDSGDSVYTQCNFSYLESNYF

CYJCBA



ELSIOTICA CENTRAL



Highest match is 20
in 1934 window(s)


4 W/Dot.

>GR-E236826 gi|1314096|gnl|EID|e236826 (271255) unknown [Saccharomyces cerevisiae]; gi|809587 (249274) unknown [Saccharomyces cerevisiae]
 MHGKELAGRLRKRENDNDLSENSSSSPAERFRCPHPECNKTFFSRQEHLRSHKLNHWPKET
 YVCSYVLPPTNAPCNKTFVRKDLLIRHEKRHSKVNRLSRPSKDQISSSNKDFSKNAPYN
 PSEVPLSTQSGTSTINLIKNSVNPPTSITQESKFRPFLQQAQQPQQVQSQPQQIQQQLQ
 QLQFPQQLRAPLQQPMLQQQMHPQQASPTFPSYDPRIRNNGQNGQFFNLIFDNRTGVNG
 FEVDAANNNGNGNDQNMNINPAVQQQRYQDRNFASSSYQQPLQPLTQDQQQEQYFQQQKL
 AQQQQQQQQQQQQQQQLPQNPFGDPLTSSSSGANLSVMQDLFSTNFLNSDFLQSFMQEL
 SEAPQVSIEDTFSKNTIPPNEKPVQDDEGPNPVMFELPQDNIKIPKAQPKENDNPST
 SVKDNLSSQKLNINELKRRSSKDSGVGNSSLNRYKEQLRHSMKSVPSFFHPDPLTKYKIS
 KEKQEMFSFVPELRYVSIESIHKSLKSFWLNPHFPQYGLLHKPSFHVQKQPAIILNIALIM
 TGASFLGSEYREQISDPICGPLRWIIFSHADFQPPSKTYIIQSLLLVGEYEKSTNRYLH
 ERSFLHHGSTNRYLHERSFLHHGSTNRYLHERSFLHHGSTNRYLHERSFLHHGSTNRYLH
 ERSFLHHGSTNRYLHERSFLHHGSTNRYLHERSFLHHGSTNRYLHERSFLHHGSTNRYLH
 ERSFLHHGSTNRYLHERSFLHHGSTNRYLHERSFLHHGSTNRYLHERSFLHHGSTNRYLH
 ERSFLHHGSTNRYLHERSFLHHGSTNRYLHERSFLHHGSTNRYLHERSFLHHGSTNRYLH
 ERSFLHHGSTNRYLHERS

CUCBA



BIBLIOTECA CENTRAL




HI0119.

MKLLKISAI SAALLSAPMM ANADVLSVK PLGFIVSSIA DGVGTQVLV PAGASPHDYN
 LKLSDIQVK SADLVVWIGE DIDSFLDKPI SQIERKKVIT IADLADVKPL LSKAHEHFH
 EDGDHHDHK HEHKHDMKHD HDHGDHDKHE HKHDHEHHDH DHHEGLTTNW HVWYSPAISK
 IVAQKVADKL TAQFPDKKAL IAQNLSDFNR TLAEQSEKIT AQLANVKDKG FYVEHDAYGY
 FNDAYGLKQT GYFTINPLVA PGAKTLAHIK EEIDEHKVNC LEAEPOPTPK VIESLAKNTH
 VNVGQLDPIG DKVTLGKNSY ATFLQSTADS YMECLAK

CUCBA



BIBLIOTECA CENTRAL




Highest match is 20
in 295 window(s)

HI1058.
 MKTDIQTELT QALLSHEKW ANEERTILAK NILDLVEKT DPTIIGLLG NDDLKRHFFV
 EVNGVLVFKL QDFRFFLDKH SINNSYTKYA NRIGLTDGNR FLKDSSDIVL DFPPKDCVLN
 GQQSTEEGEE IYFKRNNSQS VSQSVSQSVS QSVSQSVSQS VSQSVSQSVS QSVSQSVSQS
 IIHQINPKKT RNLF

CANADA



BIBLIOTECA CENTRAL




>HI1685 outer membrane integrity protein (tolA) (Escherichia coli)
 MADVLSRFNSGKLDWDFKGGIHPPEMKSQNSQPLRHLPLGTDIFYIPLKQHLGTTGNLLIK
 EGDYVLKQALTKGDLRMLPVHAPTSGTIKSIKPYVATHPSGLDEPTIHLQADGLDQWI
 ERNPIDDFSTLSSSEQLIHKIYQAGIAGLGGAVFPPTAAKIQSAEQVKLLIINGAECEPYI
 TCDDRLMRERADEIIKGIRILRYLHPEKVVIAIEDNKPEAISAIRNALQGANDISIRVI
 PTKYPSGATKQLIYLLTGI EVPSSGERSSSIGVLMQNVGTMFAIKRAIINDEPLIERVVTL
 TGNKIAEKGNVWVRLGTPISQILSDAGYQFDKHFPIFAGGPMGLELPNLNAPVTKLVNC
 LLAPDYLEYAEPEAEQACIRCSSCSDACPVNLMPPQLYWFARSEDHKKSEYALKDCIEC
 GICAYVCPSHIPLIQYFRQEKAKIWQIKKQKKSDEAKIRFEAKQARMEREQERKARSQ
 RAAQARREELAQTKGEDPVKAALERLKAKKANETESTQIKTLTSEKGEVLPDNTDLMAQR
 KARRLARQQAASQVENQEQQTQPTNAKKAAVAALARAKAKKLAQANSTSEAISNSQTAE
 NQVEKTKSAVEKTQENSTALDPKKAAVAAIARAKAKKLAQNTNSTSEAISNSQTAENEVE
 KTKSAVEKTEENSTALDAKKAATAAAIARAKAKKLAQANSASEAISNSQTAENEVEKTKS
 AVEKTOQNSTALDPKKAAVAAIARAKAKKLAQANSTSEAISNSQTAENEVEKTKSAVEK
 TQENSTALDPKKAAVAAIARAKAKKLAQNTNSTSEAISNSQTAENEVEKTKSAVEK

CUCBA



BIBLIOTECA CENTRAL



Highest match is 20
in 198 window(s)


>MJ0694

LIYVTFPTYGAFGVKDNKEVSGLEDIEYKKLFNEEEI PDIMFKLKTQPNKIADDELKEEWG
 DEIKLETLPSTPEFNIGEF LRNNLFKVGKELGYFNNDYDFRKKMHWSTELTKKVIKS YAQ
 QKDKIIQVAEAI SLDKRTLNLLSERLREWYSLYFPPELDHLVNKHEVYANLITKLGKRKN
 FTKSQLKKILPSKLAGKIAEAAKNSMGGELEDYDL DVI VKFAEEINHLYEKRRKELYNYLE
 KLMNEEAPNITKLAGVSLGARLIGLAGGLEKLA KMPASTIQVLGAEKALFAHLRMGVEPP
 KHGI IYNHPLIQGS FHWQRGKIARALACKLATAARADYVGDYIADELLEKLNKRVEEIRR
 KYPRPPK KKKKEKP KAKKKEKKGKKEKS KKKKDKKKDKKGGK KKRKVI GKT KSRK

CUCBA




BIBLIOTECA CENTRAL



>MJ1322

```
MSMILKEIRMNNEFKSHVNSRIKFEKGIVAIGENGSGKSSIPEAVFFALFGAGSNFNQYDT
IITKGGKSVYVELDFEVNGNYYKIIREYDSGRGGAKLYKNGKPYATTISAVNKAVNEILG
VDRNMFNSIYIKQGEIAKFLSLKPSEKLETVAKLLGIDEFEKCYQKMGIEVKEYEKRLE
RTEGELNYKENYKELKNKMSQLEEKNNKLMINDKLNKIKKEFEDIKLFNEWENKLL
YEKFINKLEERRKRALELNQELKILEYDLNTVVEARETLNRHKDEYEKYKSLVDEIRKIE
SRLRELKSHYEDYLKTKQLEI IKGDI EKLEKFEFINKSKYRDDIDNLDLTLNKKI KDEIERV
ETIKOLLEELKNLNEEIEKIEKYKRICEECKEYKYLELEEKAVEYNKLTLEYITLLQE
KKSIEKNINDLETRINKLLEETKNIDIESIENSLKEIEEKKKVDENLQKEKIELNKKLGE
INSEIKRLKKILDELKEVEGKCPCKTPI DENKKMELINQHKTQLNNKYTELEEINKKIR
ETEKDIEKLLKEIDKEENLKTLYLEKQSQIELELEKLNKYEQLDIENKKISNYVIN
GKPVDEILEDIKSQLNFKNFYNYQLSAVSYLNSVDEEGIRNRRIKEIENIVSGWNKEKCR
EELNKLREDEREINRLKDKLNLKXKEKELIENRRSLKFDKYKEYLGLTEKLEELKNI
KDGLEEIYNICNSKILAI DNI KRKYNKEDIEIYLNKILEVNKEINDIEBIRISYINQKLD
ETNYNEEHHKKIKELYENKRQELDNVREQTEIETGIEYLKKTVESLKRARKEMS NLEKE
KEKLT KFEVYLDKVRRI FGRNGFQAYLREKYVPLIQXYLNEAFSEFDLPYSFVELTKDFE
VRVHAPNGVLTIDNLSGGEQIAVALSLRLAANALIGNRVECIILDEPTVYLDENRRRAKI
AEIFRKKVSI PQMIIITHHRELEDVADVI INVKKDGNSVKV KING
```



Highest match is 20
in 202 window(s)


>MJ ECL23

LVMRMVVENKINGVENIRQEIDNLSVSNYKEIYDKFKNVFSKNRDIENYVVDKLIELMK
 NLDNDELSEIDKFMLCILKDSIIWEFKAGGSVWDLISKDIKDNIIILGCSNHLFALDIK
 TGNKIWEYKVEHNVDSLFIKDNIVMLEYRGGHVCVLDVMTGDKIWESKVGGERMWGFSLKD
 NIVILGDDGDKYIYADVVRTGGKLWEFEAENCWELSIKDDKIIIRCEDEYGCCEYFYVLDI
 KTGEKILEFGGEWHSVSDLLISGDVTIILADMWGCVYALDNTNLYSKIQRVRLQLTNIMKEIV
 KIDLTLKKSLNLSNDELPIQITNKS LKDIITISKISINEEDILFKDIEPIKIRGRDTK
 VINLFINPKVKGLPIDIVVEFEDEFNIRYKERFTEVLTITKFRGDNVDDMRPEKIDRIL
 QEIDNLSNTSNYKEIYSRFKNIENENRAVENYYMKNLIELVNNNSDELAINVGFELDIL
 GIKRVDELLWEFRAEGGVRLLSIKGDIVILGCVSGHVYAIIDIKTGKRLWEFKAEDTVWGL
 SIKDDIVVLGCGNIFESIVMLKNGKILEEGYAYALDINTGREIWRSKI KHDVRSLSIKDD
 IVVLGCKKGYILALDINAGNMLWEFKAESGKSIRNLSIKNDILLFGCDNYLYALDIDTGR
 ELWRPKAEGEVKLSIKKDNVLLGCRGGYVYLLDINTGKMERFKVVGSVLRLSIKDDIV
 ILGCNRECVYALDINAGENLWAFKTDGDVNGLSIKNDAVLLGCDNYLYALDINTGEEIWK
 FKTESAVLDSLKIDNIVISGCKRGHVYALDFNIIKNYSIIQIKIQVL

CUCBA



BIBLIOTECA CENTRAL



Highest match is 20
in 200 window(s)


Window = 20 Match = 5+

```
>SW-SR40_YEAST SW:SR40_YEAST P32583 saccharomyces cerevisiae (baker's
yeast). supressor protein srp40. 6/94; PIR:S38170 SRP40 protein - yeast
(Saccharomyces cerevisiae); gi|486581 (Z28317) ORF YKR092c
MASKKIKVDEVPKLSVKEKEIEEKSSSSSSSSSSSSSSSSSSSSSSSSSSSSSSSSSSSSSSSS
SSSSDSSDSDSESSSSSSSSSSSSSSSSDSESSSESDSSSSSGSSSSSSSSSSDESSSES
ESEDETKKRARESDNEDAKETKRAKTEFESSSSSESSSSSGSSSSSESESGSESDDSSSS
SSSSDSESDSESDSQSSSSSSSSDSSSDSSSDSSSDSSSDSSSDSSSSSSSSSDSDSDSDS
SSDSDSSGSDSSSSSDSSDETSDDSDSDSDSDSGSSSELETKEATADESKAEETPA
SSNESTPSASSSSSANKLNI PAGTDEI KEGQRKHFSRVDRSKINFEAWELTDNTYKGAAG
TWGEKANERLGRVRGKDFTRKNKNMKRGSYRGGSSITLESGSYKFD
```

CUCBA



BIBLIOTECA CENTRAL



Highest match is 20
in 180 window(s)

CUCBA



BIBLIOTECA CENTRAL

```
>SW-YG1F_YEAST SW:YG1F_YEAST P53214 saccharomyces cerevisiae (baker's
yeast). hypothetical 57.5 kd protein in vma7-rps31a intergenic region.
10/96; gi|1322994|gnl|PID|e243927 (Z72807) ORF YGR023w [Sac
MASCNPTRKKSSASSLSMWRTILMALTTLP LSVLSQELVPANSTTSSTAPSITSLSAVES
FTSSTDATSSASLSTPSIASVSVFTSFPQSSLLLSSTLSSELSSSMQVSSSSSTSSSS
EVTSSSSSSSISPSSSSSTIISSSSSLPFTFVASTSSTVASSTLSTSSSLVISTSSSTFT
FSSESSSLLISSSISTSVSTSSVVPSSSTSPSSSELTSYSSSSSSSTLFSYSS
FSSSSSSSSSSSSSSSSSSSSSYFTLSTSSSSSIYSSSSYPSSSSSSSNPTSSITST
SASSSITPASEYNLAKTITTSIEGQTLILSNYYTITYSPTASASSGKNSHRSGLSKKNR
NIIIGCVVIGAPLILILLILLYMFCVQPKKTDFTDSGKIVTAYRSNIFTKIWFLLGK
KIGETERESSDSPIGSNNIQFGDIDPEDI LNNDNPYTPKHTNVEGYDDDDDDANDENL
SSNFHNRGIDDQYSPTKSASYSMSNSNSQDYNDADDEVMDENIHRVYDDSEASIDENYTT
KPNGLNITNY
```

Fig. 5. Se muestran 11 secuencias de aminoácidos con su respectiva matriz de puntos, de los tres genomas microbianos analizados con el programa sclone.

De los análisis estadísticos realizados con el programa SAPS para cada secuencia se arrojaron los siguientes resultados (Cuadro 3). Se encontró que el triptofano (W) nunca participa en la baja complejidad en ninguno de los tres genomas; mientras que la cisteína (C) participa solamente en *M: jannaschii* en una proteína la ferredoxina. Los aminoácidos que se encuentran con más frecuencia en la baja complejidad varían en los tres genomas microbianos (Fig. 6).

CUCBA



BIBLIOTECA CENTRAL

Cuadro 3. Análisis con el programa SAPS

a) Composición de aminoácidos

Organismo	aa. con alta composición (++/+)	aa. con baja composición (--/-)
<i>H. influenzae</i>	SANTDIVEKQAHN	MPFLGR
<i>M. jannaschii</i>	NDIEKFY	AMSTPVQR
<i>S. cerevisiae</i>	EKHGASNTDQ	PMHDVRL

b) Distribución de cargas

organismo	% de secuencias con segmentos positivos	% de secuencias con segmentos negativos	% de secuencias con segmentos mezclados
<i>H. influenzae</i>	7.69	0	15.38
<i>M. jannaschii</i>	8.33	8.33	25
<i>S. cerevisiae</i>	13.11	21.31	37.70

c) Distribución de otros aminoácidos tipo

organismos	% de segmentos con aminoácidos hidrofóbicos	% de segmentos con aa. de transmembrana
<i>H. influenzae</i>	15.38	38.46
<i>M. jannaschii</i>	8.33	25
<i>S. cerevisiae</i>	37.70	55.73

d) Estructuras repetidas

organismo	% de secuencias que presentan patrón	% del promedio de repeticiones en las secuencias
<i>H. influenzae</i>	84.61	3.36
<i>M. jannaschii</i>	100	6.16
<i>S. cerevisiae</i>	98.36	9.9

e) Multitiplotes

organismo	% de multitiplotes extensos	% de altitiplotes extensos	% de multitiplotes significativos	% de altitiplotes significativos	aminoácidos
<i>H. influenzae</i>	0	15.38	0	0	DH, EP
<i>M. jannaschii</i>	8.33	8.33	0	16.66	K, PC, GC, EW
<i>S. cerevisiae</i>	63.93	8.47	13.11	16.94	TSNQH, GS, GY, FQ, CW, GN, AY, GS , KC, RN, RY, VP, LY, AP, GQ, PW, FG, GH, SF, ER, EY, NW , DF, DG, LF, KD, SY, ST, SF

f) Periodicidad

organismo	% de sec. con un alto número de copias	aminoácidos
<i>H. influenzae</i>	58.84	HQKEASV
<i>M. jannaschii</i>	58.33	IKE
<i>S. cerevisiae</i>	77.04	QSNTGKVDYH

g) Espacialidad

organismo	% de eventos excesivos en la distribución de aminoácidos	aminoácidos
<i>H. influenzae</i>	61.53	SINAK
<i>M. jannaschii</i>	25	KIC
<i>S. cerevisiae</i>	70.49	NQSTHEP



BIBLIOTECA CENTRAL


*Saccharomyces cerevisiae**Haemophilus influenzae**Methanococcus jannaschii*

Fig. 6. Aminoácidos que se encuentran con más frecuencia en cada genoma. Entre los aminoácidos que influyen en la baja complejidad de *H. influenzae* destacan, asparagina (N), lisina (K), y valina (V); para *M. jannaschii*, lisina (K), isoleucina (I) y ácido glutámico (E), y en *S. cerevisiae*, serina (S), treonina (T), glicina (G), glutamina (Q), ácido glutámico (E), asparagina (N) y lisina (K).

4. DISCUSION

4.1 Distribución de secuencias simples en los tres genomas microbianos.

Los análisis muestran una amplia distribución de las secuencias simples en los genomas de *H. influenzae*, *M. jannaschii* y *S. cerevisiae*, presentando diferencias en la frecuencia y composición de la baja complejidad, siendo una característica relevante en el genoma eucarionte.

La distribución funcional de las secuencias simples no esta restringida a un solo grupo funcional, sino que se encuentra en todos los grupos que propone Riley (1993). Las secuencias simples se encuentran distribuidas principalmente en el grupo funcional VII (proteínas hipotéticas y de función desconocida), pero esto puede ser provocado por el desconocimiento que aún se tiene de la biología de los genomas completos. Otro grupo funcional con una frecuencia significativa de secuencias simples es el I (metabolismo de macromoléculas). Estos dos grupos pueden ayudar a conocer el papel que han tenido las secuencias simples a lo largo de la evolución de las proteínas debido a que en el grupo de macromoléculas se encuentran proteínas con un origen anterior al último ancestro común, lo que sugiere la antigüedad del fenómeno; por otro lado la presencia de secuencias simples, en proteínas hipotéticas sugiere un papel importante del fenómeno en secuencias que no tienen una alta presión de selección.

El principal fenómeno responsable de la producción de las secuencias simples es el patinaje de la polimerasa (Bebenek y Kunkel, 1990; Richards y Sutherland, 1994; Hancock, 1995; Epplen y Riess, 1997). La creación y elongación de las secuencias simples ocurre durante la replicación del DNA (Schlötterer y

Tautz, 1991). Siendo el patinaje de la polimerasa una característica muy antigua de sistemas de replicación (Li y Nicolaou, 1994; Sievers y von Kiedrowski, 1994) es difícil estimar que tan frecuente se presenta el patinaje de la polimerasa en las especies y que tan antiguo es, pero el encontrar que este fenómeno está presente en proteínas primordiales como: DNA polimerasas, ATP-sintetasas, topoisomeras, ferredoxinas y proteínas ribosomales, sugiere que el patinaje de la polimerasa precede al último ancestro común de los seres vivos y por lo tanto es más antiguo que los organismos patógenos, hecho que establece que este fenómeno no es una adaptación de la patogénesis (Moxon *et al.*, 1994; High *et al.*, 1996; Saunders *et al.*, 1998).

La ocurrencia de las secuencias simples en varias funciones, la antigüedad de algunas proteínas y su presencia en los tres dominios, sugiere que el proceso de patinaje de la polimerasa no es solo un importante proceso en la evolución de genomas completos, sino también en el origen y evolución de proteínas.

La incorporación de secuencias simples en el genoma ha contribuido al incremento del tamaño del genoma durante la evolución, incorporando los productos del patinaje de la polimerasa (Hancock, 1996). Existe la posibilidad que al incorporarse los productos del patinaje de la polimerasa en la proteína resultante esta tenga una expresión diferente a la original, teniendo una nueva función.

En los experimentos desarrollados *in vitro* (Kornberg *et al.*, 1964), para la síntesis de la DNA polimerasa se observa un alto rango de mutaciones producidas por el patinaje de la polimerasa, pero al ser comparada con los experimentos *in vivo* (Levinson y Gutman, 1987) el número de mutaciones es muy bajo, por lo que

se ha sugerido que en eucariontes no solo actúa el patinaje de la polimerasa, sino que pueden existir algunos otros mecanismos de *turnover*, siendo el patinaje de la polimerasa el mecanismo que mejor explica la evolución del genoma (Levinson y Gutman, 1987b; Hancock, 1996). El que otros mecanismos pudieran participar en el incremento de las proteínas es muy viable, debido a que el genoma de los eucariontes es mucho más grande, lo que le permite una plasticidad de adecuación a varios mecanismos, a diferencia de los procariontes en los cuales pareciera que solo se presenta el patinaje de la polimerasa

4.2 Consecuencias de la incorporación de las secuencias simples en el genoma.

En los últimos años el interés por las secuencias simples ha estado ligado a patogénesis (Moxon *et al.*, 1994, Moxon y Wills, 1999) Los niveles elevados del patinaje de la polimerasa podría ocasionar un crecimiento incontrolado, dando como resultado enfermedades como el cáncer. Varios organismos patógenos como son: *Haemophilus influenza*, *Neisseria gonorrhoeae*, *Neisseria meningitidis*, entre otros presentan pérdida ó ganancia de repeticiones producto del patinaje de la polimerasa, estas puede generar fases de variación y modular alternativas de expresión en los genes (Moxon *et al.*, 1994). Podrían existir genes que actuaran en substratos de *slippage*, aumentando la variación por la pérdida o ganancia de repeticiones (Tautz *et al.*, 1986; Hancock y Dover, 1990; Brian y Meyer, 1992), lo que genera mayores posibilidades de adecuación positiva.

La presencia de baja complejidad en secuencias antiguas indica que este fenómeno precede a la patogénesis, lo cual sugiere que el patinaje de la

polimerasa no solo participa como un mecanismo de incremento de variabilidad en casos extremos (Becerra y Lazcano en preparación).

4.3 Distribución de los aminoácidos en las secuencias simples.

La incidencia de aminoácidos cargados, en las secuencias simples, la presencia de segmentos hidrofóbicos y de transmembrana, las estructuras repetidas y la espacialidad puede sugerir una correlación con la estructura de la proteína y su función en diversos eventos biológicos, como pueden ser la formación de dominios en membranas, activación de la transcripción, control de la división celular, en el ensamblaje de ciertas proteínas, en el incremento de su solubilidad en un medio acuoso, en la estabilidad y conformación de las mismas. Los resultados obtenidos del análisis estadístico de las secuencias simples, sugieren que no existe una correlación entre la baja complejidad con su función biológica o sus características físico-químicas, manteniendo diferentes estructuras secundarias en las proteínas en que participan.

La presencia de determinados aminoácidos en las secuencias simples, podría estar vinculada, a la facilidad de poder intercambiar un nucleótido por otro en sus codones.

CUCBA



BIBLIOTECA CENTRAL

5. CONCLUSIONES

- Las secuencias simples se encuentran distribuidas en los tres principales linajes celulares (Arquea, Bacteria y Eucaria), presentando también una alta distribución en las funciones biológicas.
- Los aminoácidos que con mayor frecuencia se presentan en las secuencias simples de los tres genomas microbianos son: (K) lisina, (E) ácido glutámico, (N) aspargina y (D) ácido aspártico.
- El análisis visual es una importante herramienta para la determinación de secuencias simples, observando principalmente la baja complejidad en los extremos amino y carboxilo.
- La baja complejidad podría jugar un importante papel en la evolución del tamaño de las proteínas, y quizás en el incremento del número de las mismas, siendo un recurso de variabilidad y posiblemente en la adquisición de nuevas funciones de las proteínas durante la evolución.
- El fenómeno de la baja complejidad es muy antiguo (antes del último ancestro común) precediendo a la patogénesis.

CUCEBA



RECTORIA CENTRAL

6. REFERENCIAS

- Alm, RA, LS. Ling, DT. Moir, BL. King, ED. Brown, PC. Doig, DR. Smith, B. Noonan, BC. Guild, BL. deJorge, G. Carmel, PJ. Tummino, A. Caruso, M. Uria-Nickelsen, DM. Mills, C. Ives, R. Gibson, D. Merberg, SD. Mills, Q. Jiang, DE. Taylor, GF. Vovis, TJ. Trust. 1999. Genomics-sequence comparison of two unrelated isolates of the human gastric pathogen *Helicobacter pylori*. **Nature 397(6715):176-80**
- Andersson, S. G, A. Zomorodipour, J. O.Andersson, T. Sicheritz-Ponten, U.C. Alsmark, R. M. Podowski, A. K. Naslund, A. S. Eriksson, H. H. Winkler, y C. G. Kurland. 1998. The genome sequence of *Rickettsia prowazekii* and the origin of mitochondria. **Nature 396(6707):133-40**
- Blattner, F.R., G.Plunkett, CA. Bloch, NT. Perna, V. Burland, M. Riley, J. Collado-Vides, JD. Glasner, CK. Rode, GF.Mayhew, J. Gregor, NT. Davis, H.A. Kirkpatrick, MA. Goeden, DJ Rose, B. Mau, Y. Shao. 1997. The complete genome sequence of *Escherichia coli* K-12. **Science 277:1453-1474**
- Bebenek, K. and Kundel TA. 1990. Frameshift errors initiated by nucleotide misincorporation. **Proc. Natl. Acad. Sci. USA 87:4946-4950**
- Brian, D. R. and Meyer T, F. 1992. Genetic variation in pathogenic bacteria. **Reviews 8(12):422-427**
- Bult, C. J., White O, G. J. Olsen, L. Zhou, R.D. Fleischmann, G. G.Sutton, J. A. Blake, L. M. FitzGerald, R. A. Clayton, J. D. Gocayn, A. R. Kerlavage, B. A. Dougherty, J. F. Tomb, M. D. Adams, C.I. Reich, R. Overbee, E.F. Kirkness, K.G. Weinstock, J. M. Merrick, A. Glodek, J. L. Scott, N.S.M. Geoghagen, J. C. Venter. 1996. Complete genome sequence of the methanogenic archaeon, *Methanococcus jannaschi*. **Science 273:1017-1140.**

- Clark, S. P., G. A. Evans, y H. R. Garden. 1997. Informatics and Automation Used in Physical Mapping of the Genome. *en* Smith, D. W. (ed), 19-49 pp. **Biocomputing Informatics and Genome Projects**. Academic Press, Inc.
- Cole, ST, R. Brosch, J. Parkhill, T. Garnier, C. Churcher, D. Harris, SV. Gordon, K. Eiglmeier, S.Gas, CE. 3er Barry, F. Tekaiia, K. Badcock, D. Basham, D. Brown, T. Chillingworth, R. Connor, R. Davies, K. Devlin, T. Feltwell, S. Gentles, N. Hamlin, S. Holroyd, T. Hornsby, K. Jagels, BG. Barrell, et al., 1998 Deciphering the biology of *Mycobacterium tuberculosis* from the complete genome sequence. **Nature 393(6685):537-44**
- Deckert, G, PV. Warren, T. Gaasterland, WG. Young, AL. Lenox, DE. Graham, R. Overbeek, MA. Snead, M. Keller, M. Aujay, R. Huber, RA. Feldman, JM. Short, GJ. Olsen, RV. Swanson. 1998. The complete genome of the hyperthermophilic bacterium *Aquifex aeolicus*. **Nature 392(6674):353-8**
- Epplen, J. T. y O. Riess. 1997. Repetitive sequences in DNA. *en* Bishop, M. J. Raulings (eds), 185-195 pp. **DNA and protein sequence analysis: a practical approach**. IRL Press, Oxford
- Fleischmann, R D, M. D. Adams, O. White, R. A. Clayton, E. F. Kirkness, A. R. Kerlavage, C. J. Bult, J. F. Tomb, B. A. Dougherty, J. M. Merrick, K. McKenney, G. Sutton, W. FitzHugh, C. Fields, J. D. Gocayne, J.Scott, R. Shirley, T. Spriggs, E. Hedblom, M. D. Cotton, T. R. Utterback, M. C. Hanna, D. T. Nguyen, D. M. Saudek, R. C. Brandon, L. D. Fine, J. L. Fritchman, J.L. Fuhrmann, NS. M.Geoghagen, C. L. Gnehm, L.A. McDonald, K. V. Small, C.M. Freiser, H. O. Smith, J.C. Venter. 1995. Whole-genome random sequencing and assembly of *Haemophilus influenzae* Rd. **Science 269, 496-512.**
- Fraser, C. M, J. D. Gocayne, O. White, M. D. Adam, R. A. Clayton, R. D. Fleischmann, C. J.Bult, A. R. Kerlavage, G. Sutt, J. M. Kelley, J. L. Fritchman, J. F. Weidman, K. V. Small, M. Sandusky, J. Fuhrmann, D. Nguyen, T. R. Utterback, D. M. Saudek, C. Phillips, J. M. Merrick, J. F. Tomb, B. A. Dougherty, K. F. Bott, P. C Hu, T.S. Lucier, S. N. Peterson, H.

- O. Smith, C. A. Hutchinson III, J. C. Venter. 1995. The minimal gene complement of *Mycoplasma genitalium*. **Science** **270**, 397-403.
- Fraser, C. M, S. Casjens, WM. Huan, GG. Sutton, R. Clayton, R. Lathigra, O. White, KA. Ketchum, R. Dodson, EK. Hickey, M. Gwinn, B. Dougherty, J. F. Tomb, R. D. Fleischmann, D. Richardson, J. Peterson, AR. Kerlavage, J. Quackenbush, S. Salzberg, M. Hanson, R. van Vugt, N. Palmer, MD. Adams, J. Gocayne, JC. Venter et al., 1997. Genomic sequence of a Lyme disease spirochaete, *Borrelia burgdorferi*. **Nature** **390(6660):580-6**
- Fraser, CM, SR. Norris, GM. Weinstock, O. White, GG. Sutton, R. Dodson, M. Gwinn, EK. Hickey, R. Clayton, KA. Ketchum, E. Sodergren, JM. Hardham, MP. McLeod, S. Salzberg, J. Peterson, H. Khalak, D. Richardson, JK. Howell, M. Chidambaram, T. Utterback, L. McDonald, P. Artiach, C. Bowman, MD. Cotton, JC. Venter et al., 1998. Complete genome sequence of *Treponema pallidum*, the syphilis spirochete. **Science** **281(5375):375-88**
- Goffeau et. al., 1997. Complete genome yeast. **Nature** **387 (Suppl.) 5-105**
- Hancock, J. M. and Dover A. G. 1990. "Compensatory slippage" in the evolution of ribosomal RNA genes. **Nucleic Acids Res** **18(20):5949-5954**
- Hancock, J. M. 1995. The contribution of slippage-like processes to the genome evolution. **J. Mol. Evol.** **41:1038-1047**
- Hancock, J. M. 1996. Simple sequence and the expanding genome. **BioEssays** **18(5)421-425**
- High, N. J, M. P. Jennings and E. R. Moxon. 1996. Tandem repeats of the tetramer 5'-CAAT-3' present in lic2A are required for phase variation but not lipopolysaccharide biosynthesis in *Haemophilus influenzae*. **Molecular Biology** **20:165-174**
- Himmelreich, R, H. Hilbert, H. Plagens, E. Pirkl, BC. Li, R. Herrmann. 1996. Complete sequence analysis of the genome of the bacterium *Mycoplasma pneumoniae*. **Nucleic Acids Res** **24(22):4420-49**
- Horowitz, N. H. 1945. On the evolution of biochemical synthesis. **Proc. Natl. Acad. Sci. USA** **31:153-157**

- Kaneko, T, S. Sato, H. Kotani, A. Tanaka, E. Asamizu, Y. Nakamura, N. Miyajima, M. Hirosawa, M. Sugiura, S. Sasamoto, T. Kimura, T. Hosouchi, A. Matsuno, A. Muraki, N. Nakazaki, K. Naruo, S. Okumura, S. Shimpo, C. Takeuchi, T. Wada, A. Watanabe, M. Yamada, M. Yasuda, S. Tabata. 1996. Sequence analysis of the genome of the unicellular cyanobacterium *Synechocystis* sp. strain PCC6803. II. Sequence determination of the entire genome and assignment of potential protein-coding regions. **DNA Res.** **3(3):109-36**
- Kawarabayasi, Y, M. Sawada, H. Horikawa, Y. Haikawa, Y. Hino, S. Yamamoto, M. Sekine, S. Baba, H. Kosugi, A. Hosoyama, Y. Nagai, M. Sakai, K. Ogura, R. Otsuka, H. Nakazawa, M. Takamiya, Y. Ohfuku, T. Funahashi, T. Tanaka, Y. Kudoh, J. Yamazaki, N. Kushida, A. Oguchi, K. Aoki, H. Kikuchi. 1998. Complete sequence and gene organization of the genome of a hyperthermophilic archaeobacterium, *Pyrococcus horikoshii* OT3 (supplement). **DNA Res** **5(2):147-55**
- Klenk, HP, RA. Clayton, JF. Tomb, O. White, KE. Nelson, KA. Ketchum, RJ. Dodson, M. Gwinn, EK. Hickey, JD. Peterson, DL. Richardson, AR. Kerlavage, DE. Graham, NC. Kyrpides, RD. Fleischmann, J. Quackenbush, NH. Lee, GG. Sutton, S. Gill, EF. Kirkness, BA. Dougherty, K. McKenney, MD. Adams, B. Loftus, JC. Venter, et al. , 1997. The complete genome sequence of the hyperthermophilic, sulphate-reducing archaeon *Archaeoglobus fulgidus*. **Nature** **390(6658):364-70**
- Kornberg A, LL. Bertsch, JF. Jackson, HG. Khorana. 1964. Enzymatic synthesis of deoxyribonucleic acid, XVI. Oligonucleotides as templates and the mechanism of their replication. **Proc. Natl. Acad. Sci. USA** **51:315-323**
- Kunst, F, N. Ogasawara, I. Moszer, AM. Albertini, G. Alloni, V. Azevedo, MG. Bertero, P. Bessieres, A. Bolotin, S. Borchert, R. Borriss, L. Boursier, A. Brans, M. Braun, SC. Brignell, S. Bron, S. Brouillet, CV. Bruschi, B. Caldwell, V. Capuano, NM. Carter, SK. Choi, JJ. Codani, IF. Connerton, A. Danchin, et al., 1997. The complete genome sequence of the gram-positive bacterium *Bacillus subtilis*. **Nature** **390(6657):249-56**

- Levinson, G. and Gutman GA. 1987. High frequencies of short frameshifts in poly-CA/TG tandem repeats borne by bacteriophage M13 in *Escherichia coli* K-12. **Nucleic Acids Res.** 15:5323-39
- Levinson, G. and Gutman GA. 1987b. Slipped-strand mispairing: a major mechanism for DNA sequence evolution. **Mol. Biol. Evol.** 4(3):203-21
- Li, T. and Nicolaou K. C. 1994. Chemical self-replication of palindromic duplex DNA. **Nature** 369:218-220
- Moxon, E. R. P.B. Rainer. M. A. Nowak, and R. E. Lenski. 1994. Adaptive evolution of highly mutable loci in pathogenic bacteria. **Curr. Biol.** 4:24-33
- Moxon, R. and Wills C. 1999. DNA microsatellites: Agents of evolution?. **Scientific American Jan 94-99**
- Riley, M. 1993. Functions of the Gene Products of *Escherichia coli* **Microbiological Reviews** 57(4):862-952
- Richards, R I. and Sutherland GR. 1994. Simple repeat DNA is not replicated simply. **Nature Genet** 6:114-116
- Saunders, N J, Peden J F, Hood D W, Moxon R. 1998. Simple sequence repeats in the *Helicobacter pylori* genome. **Molecular Microbiology** 27:1091-1098
- Schlötterer, C. and Tautz D. 1991. Slippage synthesis of simple sequence DNA. **Nucleic Acids Res.** 20:211-215
- Sequencing Consortium. 1999. Genome Sequence of Nematode *C. elegans*: A platform for Investigating Biology. **Science** 282:2012-2018
- Sievers, D. and von Kiedrowski. 1994. Self-replication of complementary nucleotide-based oligomers. **Nature**, 369:221-224
- Smith, DR, LA. Doucette-Stamm, C. Deloughery, H. Lee, J. Dubois, T. Aldredge, R. Bashirzadeh, D. Blakely, R. Cook, K. Gilbert, D. Harrison, L. Hoang, P. Keagle, W. Lumm, B. Pothier, D. Qiu, R. Spadafora, R. Vicaire, Y. Wang, J. Wierzbowski, R. Gibson, N. Jiwani, A. Caruso, D. Bush, JN. Reeve, et al., 1997. Complete genome sequence of *Methanobacterium thermoautotrophicum* deltaH: functional analysis and comparative genomics. **J. Bacteriol** 179(22):7135-55

- Stephens, RS, S. Kalman, C. Lammel, J. Fan, R. Marathe, L. Aravind, W. Mitchell, L. Olinger, RL. Tatusov, Q. Zhao, EV. Koonin, RW. Davis. 1998. Genome sequence of an obligate intracellular pathogen of humans: *chlamydia trachomatis*. **Science** **282(5389):754-9**
- Tautz, D., Trick M. and Dover G A. 1986. Cryptic simplicity in DNA is a major source of genetic variation. **Nature** **322: 652-656**
- Tautz D. and Schötterer C. 1994. Simple sequences. **Current Opinion in Genetic and Development** **4:832-837**
- Tomb, JF, O. White, AR. Kerlavage, RA .Clayton, GG. Sutton, RD. Fleischmann, KA. Ketchum, HP. Klenk, S. Gill, BA. Dougherty, K. Nelson, J. Quackenbush, L. Zhou, EF. Kirkness, S. Peterson, B. Loftus, D. Richardson, R. Dodson, HG. Khalak, A. Glodek, K. McKenney, LM. Fitzegerald, N. Lee, MD. Adams, JC. Venter et al. ,1997. The complete genome sequence of the gastric pathogen *Helicobacter pylori*. **Nature** **7:388(6642):539-47**
- Waley, S.G. 1969. Some aspects of the evolution of metabolic pathways. **Comp.Biochem. Physiol.** **30, 1-7**
- Woese, C.R. and Fox, G.E. 1977.The concept of cellular evolution. **J. Mol. Evol.** **10: 1-6**
- Woese, C. R., O. Kandler and M. L. Wheelis. 1990. Towards a natural system of organisms: proposal for the domains Archea, Bacteria, and Eukarya. **Proc. Natl. Acad. Sci. USA.** **87:4576**
- Wootton, J. and Federhen S. 1993. Statiscs of local complexity in amino acid sequences and sequence databases. **Computers Chem.** **17:149-163**
- Wootoon, J. 1997. Simple sequences of protein and DNA. *en* Bishop, M. J. Raulings (eds), 185-195 pp. **DNA and protein sequence analysis: a practical approach.** IRL Press, Oxford

7. APÉNDICE

I. Formulario.

Basado en la complejidad del estado del vector de una ventana de la secuencia, la complejidad composicional local K_1 , así como la información necesaria por posición, obtenida de la composición de la ventana de un residuo de la secuencia en particular. De un alfabeto de N -residuos (usualmente $N=4$ o

$$K_1 = \frac{1}{L} \log_N \left[\frac{L!}{\prod_{i=1}^N n_i!} \right]$$

20) y una ventana de extensión L :

Donde n_i es N números en la complejidad del estado del vector. El logaritmo es tomado como base N en el rango de 0 a 1. La complejidad es expresada frecuentemente en las unidades de información, los algoritmos son expresados en base 2, bits, base e ó nats.

Otra medida de información de la complejidad composicional local, K_2 , usualmente expresada en bits, algunas veces usada en lugar de K_1 .

$$K_2 = - \sum_{i=1}^N \frac{n_i}{L} \left[\log_2 \frac{n_i}{L} \right]$$

K_2 es una aproximación que converge hacia K_1 en una ventana extensa.

Probabilidad del estado de complejidad.

Asumiendo una probabilidad igual en apariencia de los cuatro nucleótidos o de los 20 aminoácidos, la probabilidad P_0 de la ocurrencia de algún estado de complejidad es:

$$P_0 = \frac{1}{N^L} \left(\frac{L!}{\prod_{i=1}^N n_i!} \right) \left(\frac{N!}{\prod_{\kappa=0}^L r_{\kappa}!} \right)$$

Donde r_{κ} es el total de los números en el tiempo, los números K ocurren en el número de n_i de la complejidad del estado del vector. (Wootton y Federhen, 1993).

CUCBA



BIBLIOTECA CENTRAL

II. Programa Shell-Unix

```

grep '[a-z]' archivo30 > file2
grep -n '.' file2 > file3
grep -v '[\>]' file3 > file4
cut -d":" -f1 file4 > file5
awk -f prog1 file5 > file6
grep -n '.' file3 > compar
egrep -f file6 compar > resultado1.1
cut -d":" -f3-8 resultado1.1 > res1.0
grep '[\>]' res1.0 > resultado
rm file*
rm compar
rm resultado1.1
grep -n '.' res1.0 > res2
grep -v '[\>]' res2 > res3
cut -d":" -f1 res3 > res4
awk -f prog1 res4 > res5
grep -n '.' res2 > compar1
egrep -f res5 compar1 > resultado1.2
cut -d":" -f3-8 resultado1.2 > res2.0
grep '[\>]' res2.0 > resultado1
rm res1.0
rm res2
rm res3
rm res4
rm res5
rm compar1
rm resultado1.2
grep -n '.' res2.0 > res2.2
grep -v '[\>]' res2.2 > res2.3
cut -d":" -f1 res2.3 > res2.4
awk -f prog1 res2.4 > res2.5
grep -n '.' res2.2 > compar2
egrep -f res2.5 compar2 > resultado2.2
cut -d":" -f3-8 resultado2.2 > res3.0
grep '[\>]' res3.0 > resultado2
rm res2.0
rm res2.2
rm res2.3
rm res2.4
rm res2.5
rm compar2
rm resultado2.2
grep -n '.' res3.0 > res3.2
grep -v '[\>]' res3.2 > res3.3
cut -d":" -f1 res3.3 > res3.4
awk -f prog1 res3.4 > res3.5
grep -n '.' res3.2 > compar3
egrep -f res3.5 compar3 > resultado3.2

```

CUCBA



BIBLIOTECA CENTRAL

```

cut -d":" -f3-8 resultado3.2 > res4.0
grep '[\>]' res4.0 > resultado3
rm res3.0
rm res3.2
rm res3.3
rm res3.4
rm res3.5
rm compar3
rm resultado3.2
prog1
{ s=$1-1   print ":"s:""}

```

Palabras claves para cada grupo funcional.

I. Metabolismo de macromoléculas.

ribosomal, RNA, tRNA, DNA, transcription, recombination, translocation, modification, helicase, rRNA, polimerase, histone, chromosome, elongation, topoisomerase, factor, RNase, exonuclease, endonuclease, peptidase, protease, restriction, ribonuclease, gyrase, UV, primosomal, ribonucleotide, peptidyl, polynucleotide, DNAk, DNAj, DNAc, phosphotransferase, toIA, VacB, translocation, transkelotase, protein synthesis, ribosome, chromatin, nuclear.

II. Metabolismo Intermediario.

degradation, intermediary, aerobic, anaerobic, fermentation, ATP, proton, broad, regulatory, CoA, energy, cytochrome, NADH, dehydrogenase, pyruvate, hydrolase, carbon, hydrogenase, nitrogen, fumarate, chlorohydrolase, NADH-, ferredoxin, polyferredoxine.

III. Biosíntesis de moléculas pequeñas.

amino acid, glutamate, nitrogen assimilation, aspartame, pyruvate, glycine, serine, sulfur, aromatic amino acid, histidine, nucleotides, salvages, sugar, cofactor, purine, pyrimidine, ribonucleotides, biotin, folic acid, lipoate, molybdoberin, pantothenase, pyridoxine, pyridoxal, thiamine, riboflavine, thioredoxin, glutaredoxine, glutaredoxine, glutathione, menaquinone,

ubiquinones, heme, porphyrins, fatty acids, lipids, polyamine, glutathione, argininosuccinate, glucose, phosphoribosyl, aminoimidazole, ADP-heptose, carbamoyl, orotate, GMP, GTP, UMP, CTP, AMP, phosphoribosyltransferase, quinolinate, nicotinate, thiamin, phosphatidylglycerophosphate, hemolysin, mannosyltransferase, translocase, erp, xylanase, cobalamin, geranyl, chorismate, alginate, oxaloacetate, uridylate, cytidylyltransferase, glycerol, glucosamine, phosphomannomutase, urease, urea, lipoamide, dehydrolipoamide, aliphatic, glucanase, pyridine, L-alanine, picolinate, dihydropicolinate, formate, glycogen, xylulokinase, fucosyltransferase, uridylatecytidylyltransferase, glycolysis, fructose, arginine, fatty, sterol, glycosylation, glyoxylate, phospholipid.

IV. Procesos celulares.

transport, cell division, chemotaxis, secretion, osmotic, enterobactin, permease, molybdate uptake, septum, antibiotic, chemotactic, suppressor, osmotically, potassium, channel, cation, efflux, binding, maturation, Na, Na(+), signal, chaperon, grpE, division, transposase, regulated, antiporter, cell cycle, meiosis, homeostasis.

V. Estructura celular.

cell wall, cytoskeleton, endomembrane, surface, cytoplasmic, pore, outer membrane, periplasmic, murein, UDP, flagellar, lipoprotein.

VI. Otras funciones.

cryptic, phage, prophages, colicin, plasmid, drug, radiation, colicins, azaserine, integration, terminus, heat shock, chaperone, PEP, nodulation, stress, Hsp, coenzyme, cytotoxin, pathogenicity, antigen, spore, tolerance, emergence, flocculation.

VII. Hipotéticas y función desconocida.

hypothetical, unknown, ORF.

CUCBA



FEDERACION GENERAL

III. Programa Seg.

DOCUMENTATION OF SEG (FROM 'MAN' PAGE)

 NAME

seg - segment sequence(s) by local complexity

SYNOPSIS

seg sequence [W] [K(1)] [K(2)] [-x] [options]

DESCRIPTION

 seg divides sequences into contrasting segments of low-complexity and high-complexity. Low-complexity segments defined by the algorithm represent "simple sequences" or "compositionally-biased regions".

Locally-optimized low-complexity segments are produced at defined levels of stringency, based on formal definitions of local compositional complexity (Wootton & Federhen, 1993). The segment lengths and the number of segments per sequence are determined automatically by the algorithm.

The input is a FASTA-formatted sequence file, or a database file containing many FASTA-formatted sequences. seg is tuned for amino acid sequences. For nucleotide sequences, see EXAMPLES OF PARAMETER SETS below.

The stringency of the search for low-complexity segments is determined by three user-defined parameters, trigger window length [W], trigger complexity [K(1)] and extension complexity [K(2)] (see below under PARAMETERS). The defaults provided are suitable for low-complexity masking of database search query sequences [-x option required, see below].

OUTPUTS AND APPLICATIONS

-
- (1) Readable segmented sequence [Default]. Regions of contrasting complexity are displayed in "tree format". See EXAMPLES.
 - (2) Low-complexity masking (see Altschul et al, 1994). Produce a masked FASTA-formatted file, ready for input as a query sequence for database search programs such as BLAST or FASTA. The amino acids in low-complexity regions are replaced with "x" characters [-x option]. See EXAMPLES.
 - (3) Database construction. Produce FASTA-formatted files containing low-complexity segments [-l option], or high-complexity segments [-h option], or both [-a option]. Each segment is a separate sequence entry with an informative header line.

ALGORITHM

The SEG algorithm has two stages. First, identification of approximate raw segments of low-complexity; second local optimization.

At the first stage, the stringency and resolution of the search for low-complexity segments is determined by the W, K(1) and K(2) parameters. All trigger windows are defined, including overlapping windows, of length W and complexity less than or equal to K(1). "Complexity" here is defined by equation (3) of Wootton & Federhen (1993). Each trigger window is then extended into a contig in both directions by merging with extension windows, which are overlapping windows of length W and complexity less than or equal to K(2). Each contig is a raw segment.

At the second stage, each raw segment is reduced to a single optimal low-complexity segment, which may be the entire raw segment but is usually a subsequence. The optimal subsequence has the lowest value of the probability P(0) (equation (5) of Wootton & Federhen, 1993).

PARAMETERS

These three numeric parameters are in obligatory order after the sequence file name.

Trigger window length [W]. An integer greater than zero [Default 12].

Trigger complexity. [K1]. The maximum complexity of a trigger window in units of bits. K1 must be equal to or greater than zero. The maximum value is 4.322 (log[base 2]20) for amino acid sequences [Default 2.2].

Extension complexity [K2]. The maximum complexity of an extension window in units of bits. Only values greater than K1 are effective in extending triggered windows. Range of possible values is as for K1 [Default 2.5].

OPTIONS

The following options may be placed in any order in the command line after the W, K1 and K2 parameters:

- a Output both low-complexity and high-complexity segments in a FASTA-formatted file, as a set of separate entries with header lines.
- c [characters-per-line] Number of sequence characters per line of output [Default 60]. Other characters, such as residue numbers, are additional.
- h Output only the high-complexity segments in a FASTA-formatted file, as a set of separate entries with header lines.

- l Output only the low-complexity segments in a FASTA-formatted file, as a set of separate entries with header lines.
- m [length] Minimum length in residues for a high-complexity segment [default 0]. Shorter segments are merged with adjacent low-complexity segments.
- o Show all overlapping, independently-triggered low-complexity segments [these are merged by default].
- q Produce an output format with the sequence in a numbered block with markings to assist residue counting. The low-complexity and high-complexity segments are in lower- and upper-case characters respectively.
- t [length] "Maximum trim length" parameter [default 100]. This controls the search space (and search time) during the optimization of raw segments (see ALGORITHM above). By default, subsequences 100 or more residues shorter than the raw segment are omitted from the search. This parameter may be increased to give a more extensive search if raw segments are longer than 100 residues.
- x The masking option for amino acid sequences. Each input sequence is represented by a single output sequence in FASTA-format with low-complexity regions replaced by strings of "x" characters.

EXAMPLES OF PARAMETER SETS

Default parameters are given by 'seg sequence' (equivalent to 'seg sequence 12 2.2 2.5'). These parameters are appropriate for low-complexity masking of many amino acid sequences [with -x option].

Database-database comparisons:

More stringent (lower) complexity parameters are suitable when masked sequences are compared with masked sequences. For example, for BLAST or FASTA searches that compare two amino acid sequence databases, the following masking may be applied to both databases:

```
seg database 12 1.8 2.0 -x
```

Homopolymer analysis:

To examine all homopolymeric subsequences of length (for example) 7 or greater:

```
seg sequence 7 0 0
```

Non-globular regions of protein sequences:

Many long non-globular domains may be diagnosed at longer window lengths, typically:

```
seg sequence 45 3.4 3.75
```

For some shorter non-globular domains, the following set is appropriate:

seg sequence 25 3.0 3.3

Nucleotide sequences:

The maximum value of the complexity parameters is 2 (log(base 2)4).
For masking, the following is approximately equivalent in effect
to the default parameters for amino acid sequences:

seg sequence.na 21 1.4 1.6

CUCBA



EXAMPLES

The following is a file named 'prion' in FASTA format:

```
>PRIO_HUMAN MAJOR PRION PROTEIN PRECURSOR
MANLGCWMLVLFVATWSDLGLCKKRPKPGGWNTGGSRYPGQGSPPGGNRYPPQGGGGWGQP
HGGGGWQPHGGGGWQPHGGGGWQPHGGGGWQGGGTHSQWNKPSKPKNMCKHMAGAAAAGA
VVGGLGGYMLGSAMSRPIIHFGSDYEDRYRENMHRYPNQVYYRPMDEYSNQNNFVHDCV
NITIKQHTVTTTTKGENFTETDVKMMERVVEQMCITQYERESQAYYQRGSSMVLFSPPV
ILLISFLIFLIVG
```

The command line:

```
seg prion
```

gives the standard output below

```
>PRIO_HUMAN MAJOR PRION PROTEIN PRECURSOR
1-49  MANLGCWMLVLFVATWSDLGLCKKRPKPGG
WNTGGSRYPGQGSPPGNRY
ppqggggwgqphggggwqphggggwqphgg 50-94
gwgqphggggwqggg
95-112  THSQWNKPSKPKNMCKHM
113-135
agaaaagavvgglggymlgsams 136-187
RPIIHFGSDYEDRYRENMHRYPNQVYYRP
MDEYSNQNNFVHDCVNITIKQH
tvttttkgenftet 188-201
202-236  DVKMMERVVEQMCITQYERESQAYYQRGSS
MVLFS
sppvillisflifliv 237-252
253-253  G
```

The low-complexity sequences are on the left (lower case) and high-complexity sequences are on the right (upper case). All sequence segments read from left to right and their order in the sequence is from top to bottom, as shown by the central column of residue numbers.

The command line:

```
Seg prion x
```

BIBLIOTECA CENTRAL

gives the following FASTA-formatted file:-

```
>PRIO_HUMAN MAJOR PRION PROTEIN PRECURSOR
MANLGCWMLVLFVATWSDLGLCKRPKPGGWNTGGSRYPGQGS PGGNRYxxxxxxxxxxxx
xxxxxxxxxxxxxxxxxxxxxxxxxxxxxxxxxxxxxxxxxTHSQWNKPSKPKTNMKHMxxxxxxxx
xxxxxxxxxxxxxxxxxxRPIIHFGSDYEDRYYRENMHRYPNQVYYRPMDEYSNQNNFVHDCV
NITIKQHxxxxxxxxxxxxxxxxxVKKMMERVVQMCITQYERESQAYYQRGSSMVLFSxxxx
xxxxxxxxxxxxxxxxxG
```

SEE ALSO

segn, blast, saps, xnu

AUTHORS

John Wootton: wootton@ncbi.nlm.nih.gov
Scott Federhen: federhen@ncbi.nlm.nih.gov

National Center for Biotechnology Information
Building 38A, Room 8N805
National Library of Medicine
National Institutes of Health
Bethesda, Maryland, MD 20894
U.S.A.

PRIMARY REFERENCE

Wootton, J.C., Federhen, S. (1993) Statistics of local complexity in amino acid sequences and sequence databases. *Computers & Chemistry* 17: 149-163.

OTHER REFERENCES

Wootton, J.C. (1994) Non-globular domains in protein sequences: automated segmentation using complexity measures. *Computers & Chemistry* 18: (in press).

Altschul, S.F., Boguski, M., Gish, W., Wootton, J.C. (1994) Issues in searching molecular sequence databases. *Nature Genetics* 6: 119-129.

Wootton, J.C. (1994) Simple sequences of protein and DNA. In: *Nucleic Acid and Protein Sequence Analysis: A Practical Approach*. (Second Edition, Chapter 8, Bishop, M.J. and Rawlings, C.R. Eds. IRL Press, Oxford) (In press).

CUCBA



BIBLIOTECA CENTRAL

IV. Hojas de resultados de una secuencia, con el programa SAPS y dos disquettes con todos los resultados estadísticos de las 86 secuencias simples para los tres genomas microbianos. Lista de nombres de los archivos.

S. cerevisiae 171388, 172526, 311109, 396560, 4076, 544510, 694125, 871535, 899399, aga1, albyg, amyh, chit, e190152, e239064, e245919, e245920, e252294, e252336, e252990, e312887, hkr1, kfd3, mcm1, msb2, n100, n145, nu57, pir3, ppz2, S77699, S61977, S61046, sed1, yag3, ycc8, ycx9, yg1f, yg3r, yh11, yib1, yk82, ynw8, sr40, ssn6, uso1, yir7, yj9p, ykf4, ynj1, ynr6, 251944, 854443, 927801, D1020, dr48, e236826, e252970, e308403, kai1, nsr1 m62

H. influenzae HI066, HI0251, HI0264, HI0383, HI0915, HI1058, HI1232, HI1685, HI1718, HI0119, HI0990, HI1601, HI1284

M. jannaschii MJ1254, MJ1322, MJ1422, MJ1505, MJECL28, MJ1303, MJECL23, MJ0124, MJ0233, MJ0487, MJ0694, MJ0875

CUCBA



BIBLIOTECA CENTRAL

>SW-YK82_YEAST SW:YK82_YEAST P36170 saccharomyces cerevisiae (baker's yeast). hypothetical
 122.2 kd protein in sirl 3'region precursor. 6/94; PIR:S38181 flocculation protein FLO1
 homolog YKR102w - yea
 SWISS-PROT ANNOTATION:
 ID Unknown CONVERTED; PRT; 1169 AA.
 DE unknown.
 CC SEQIO retrieval from FASTA-format entry. 19-Jan-1998

number of residues: 1169; molecular weight: 122.2 kdal

```

1  MPVAARYIFL TGLFLLSVAN VALGTTEACL PAGEKKGMT INFYQYSLKD SSTYSNPSYM
61  AYGADAERL GSVSGQTKLS IDYSIPCNGA SDTCACSDDD ATEYSASQV PVKRGVKLCS
121 DNTLTSSKTE KRENDCCDQG AAWSSDLFG FYTTPINVTV EMTGYFLPPK TGTYFGFAT
181 VDDGALLSVG GNVAFCCKQ EQPPIITSTDF TINGIKPWNA DAPTDIKGST YMYAGYYPI
241 KIVYSNAVSW GTLPVSVLPL DGEVNDDFE GYVFSFDNA TQAHCSVPNP AEHARTCVSS
301 ATSSWSSESV CTCTCTEST SYVTPYVTS SWSSESVECTE CTCTESTSTS TPYVTSSSS
361 SSEVCTECTE TESTSYVTPY VSSSTAAANY TSSFSSESSEV CTCTESTEST STSPYVTS
421 SWSSESVECTE CTCTESTSYV TPYVSSSTAA ANYTSSFSSES SEVCTECTEST ESTSTSPYV
481 TSSSSSSSEV CTCTCTEST SYVTPYVSSS TAAANYTSSS SSSSEVCTEC TETESTST
541 PYVTSSSWS SEVCTECTET ESTSYVTPYV SSSSTAAANYT SSFSSSEVC TECTESTS
601 TSTPYATSST GTATSFTAST SNTMTSLVQT DITVFSLSL TVSEHTNAPT SSVESNASTP
661 ISSNKGSVKS YVTSSIHST PMYPNSQVTD SSSVSTPIT SSSSESASV TILPSTITSE
721 PKPSTMTKV VSISSPNTL ITSYDITTKD STVGSSTSSV SLISSILPS SYSASSEQIF
781 HSSIVSNGQ ALTSFSSSTKV SSSSESSEHR TSPTTSSSESG IKSSGVIEIS TSTSSFSFHE
841 TSTASTSVQI SSQFVTPSSP ISTVAPRSTG LNSQTESTNS SKETMSEENS ASVMPSSSAT
901 SPKTKGVTS D ETSSGFSRDR TTVYRMTSET PSTNEQTILI TVSSCESNCS SNTVSSAVS
961 TATTINGIT TEYTWCPLES ATELITVSKL ESEKTLITL VTSCEGVCES TNSPAPVST
1021 ATATVNDVVT VYSTWSPQAT NKLAVSSDIE NSASKASVFS EAAETKISIR EAAVFPVTSOT
1081 TSIETHHTTT SNASENSDNV SASEAVSSKS VTNPVLISVS QQPRGTASS MIGSSSTASLE
1141 MSSYLGIANH LLTNSGISIF IASLLLAIV
  
```

CUCBA



BIBLIOTECA CENTRAL

COMPOSITIONAL ANALYSIS (extremes relative to: swp23s.g)

The composition of the input sequence is evaluated relative to the residue usage quantile table specified with the '-s species' flag. Low usage in the 1% quantile is indicated by the label '--' (e.g., Y-- means that the input sequence uses tyrosine as little as the 1% least tyrosine containing proteins in the reference set); low usage in the 5% quantile is indicated by the label '-' (e.g., L-); high usage above the 95% quantile point is indicated by the label '+' (e.g., A+); and high usage above the 99% quantile point is indicated by the label '++' (e.g., LIVFM++). The usage is evaluated for all 20 amino acids, positive (KR) and negative (ED) charge, total charge (KRED), net charge (KR-ED), major hydrophobics (LVIFM), and the groupings ST, AGP (encoded by CCN, GCN, and GGN codons), and FIKMNY (encoded by AAN, AUN, UAN, and UUN codons).

A : 72 (6.2%); C : 35 (3.0%); D : 30 (2.6%); E : 85 (7.3%); F : 30 (2.6%)
 G : 38 (3.3%); H : 9 (0.8%); I : 42 (3.6%); K : 31 (2.7%); L--: 38 (3.3%)
 M : 13 (1.1%); N : 45 (3.8%); P : 49 (4.2%); Q- : 18 (1.5%); R--: 11 (0.9%)
 S++:283(24.2%); T++:194(16.6%); V : 90 (7.7%); W : 9 (0.8%); Y : 47 (4.0%)

KR - : 42 (3.6%); ED : 115 (9.8%); AGP : 159 (13.6%);
 KRED : 157 (13.4%); KR-ED - : -73 (-6.2%); FIKMNY : 208 (17.8%);
 LVIFM - : 213 (18.2%); ST ++: 477 (40.8%).

CHARGE DISTRIBUTIONAL ANALYSIS

The distribution of charges in the protein sequence is evaluated in terms of clusters, high scoring segments, and runs and periodic patterns. Clusters indicate regions of typically 30 to 60 residues exhibiting a relatively high charge concentration. For high scoring charge segments, positive scores are assigned to charge residues of the appropriate type and negative scores to all other residues. A significant cumulative positive score again indicates a region of high charge concentration. The cluster method and the scoring method will generally pick out the same segments (with the scoring method often delimiting the segment to a narrower range), conferring robustness to the results. Short segments of high charge concentration are displayed as runs (with errors). Periodic pat-

terns focus on those with charges every second or third position, with possible relevance to amphipathic secondary structures; other periodic patterns are displayed in the general periodicity analysis section of the output.

```

1 00000+0000 0000000000 000000-000 000-++0000 00000000+- 0000000000
61 00000-0-+0 0000000+00 0-00000000 0-00000--- 00-0000000 00++00+000
121 -000000+0- ++-0--0-00 000000-000 0000000000 -00000000+ 0000000000
181 0--0000000 00000-00+0 -0000000-0 00000+0000 -000-0+000 0000000000
241 +000000000 0000000000 -00-00--0- 000000--00 0000000000 0-00+00000
301 000000000-0 00-00-0-00 0000000000 00000-000- 00-0-00000 0000000000
361 00-000-00- 0-00000000 0000000000 000000000-0 00-00-0-00 0000000000
421 00000-000- 00-0-00000 0000000000 0000000000 0-000-00-0 -0000000000
481 00000000-0 00-00-0-00 0000000000 0000000000 0000-000-0 0-0-000000
541 0000000000 0-000-00-0 -000000000 0000000000 00000000-0 0-00-0-000
601 0000000000 0000000000 0000000000 -000000000 000-000000 000-000000
661 0000+000+0 0000000000 0000000000 0000000000 0-00-00000 0000000000-
721 0+0000+0+0 0000000000 0000-000+- 0000000000 0000000000 000000-000
781 0000000000 00000000+0 000-00-00+ 0000000-00 0+000-0-0 000000000-
841 0000000000 0000000000 000000+000 00000-0000 0+-0000-00 0000000000
901 00+00+000- -000000++ 0000+000-0 0000-00000 00000-0000 0000000000
961 0000000000 0-00000000 00-00000+0 -0---+00000 0000-00000 -0000000000
1021 000000-000 0000000000 0+00000-0 0000+00000 -00-0+000+ 0000000000
1081 000-000000 0000-00-00 000-0000+0 0000000000 000+000000 0000000000-
1141 0000000000 0000000000 000000000

```

A. CHARGE CLUSTERS.

Positive, negative, and mixed charge clusters are distinguished. In each case, *cmin* indicates the minimum number of charges required for a significant charge cluster corresponding to the given window size; e.g., *cmin* = 9/30 or 12/45 or 15/60 means that significance requires at least 9 charges in a segment of 30 (or fewer) residues, or 12 charges in a segment of length 45, or 15 charges in a segment of length 60. In the case of positive and negative charge clusters, these counts refer to net charge, i.e., charges of the opposite sign within the window are counted as -1. The sizes of the clusters are optimized for display to indicate the segment of highest charge concentration, but a minimum size of 20 residues is required. A mixed charge cluster that begins and ends within 15 residues of the endpoints of a pure charge cluster is not displayed (since its significance rests mostly on the charged residues comprising the displayed pure charge cluster), unless the -v (verbose output) flag is set, in which case both the pure and the mixed charge cluster are displayed. On the other hand, pure charge clusters that are embedded in mixed charge clusters are displayed separately (indicated by a * preceding the specification of location).

For each cluster are given its location in the sequence (From, to), the quartile of the location (1st, 2nd, 3rd, or 4th quarter of the sequence), length, count, and t-value (standard deviations above the mean; to accommodate the multiple tests performed, the t-value significance threshold is set to 4.0 for sequences up to 750 residues, to 4.5 for sequences of length 750-1500 residues, and to 5.0 for longer sequences); also indicated are residues comprising at least 10% of the cluster.

Positive charge clusters: not evaluated (frequency of + < 5%, too low)

Negative charge clusters (*cmin* = 10/30 or 13/45 or 16/60): none

Mixed charge clusters (*cmin* = 12/30 or 16/45 or 19/60):

```

1) From 92 to 138: DTCACSDDDATEYSASQVVPVKRGVKLCSDNNTLLSSKTEKRENDCCD
-00000--00-000000000++00+000-000000+0-+-0--0-
quartile: 1; size: 47, +count: 6, -count: 11, 0count: 30; t-value: 4.57 *
S: 6 (12.8%); T: 5 (10.6%); D: 8 (17.0%); ST: 11 (23.4%);

```

CUCBA



BIBLIOTECA CENTRAL

B. HIGH SCORING (UN)CHARGED SEGMENTS.

For each scoring scheme (scores assigned to residues as displayed), SAPS displays segments of the sequence with aggregate score exceeding the particular threshold values $M_{0.01}$ (1% significance level, segments labeled with **), $M_{0.05}$ (5% significance level, segments labeled *), or otherwise as indicated. A minimal segment length is set as shown. The expected score/letter should be sufficiently large negative, and the average information per letter should be sufficiently large positive in order for the scoring statistics to apply properly (the program prints out when the conditions are not met and skips evaluations).

High scoring positive charge segments:

score= 2.00 frequency= 0.036 (KR)
 score= 0.00 frequency= 0.000 (BZX)
 score= -1.00 frequency= 0.866 (LAGSVTIPNFQYHMCW)
 score= -2.00 frequency= 0.098 (ED)

Expected score/letter: -0.991; Average information/letter: 3.234
 Minimal length of displayed segments set to: 20

$M_{0.01}$ = 6.98 (cv= 4.53, lambda= 1.56007, k= 0.46361, x= 2.46;
 90% confidence interval for segment length: 5 +- 4)
 $M_{0.05}$ = 5.94 (x= 1.41)

of segments (>=20 residues) exceeding $M_{0.05}$: none

High scoring negative charge segments:

score= 2.00 frequency= 0.098 (ED)
 score= 0.00 frequency= 0.000 (BZX)
 score= -1.00 frequency= 0.866 (LAGSVTIPNFQYHMCW)
 score= -2.00 frequency= 0.036 (KR)

Expected score/letter: -0.741; Average information/letter: 1.341
 Minimal length of displayed segments set to: 20

$M_{0.01}$ = 11.08 (cv= 7.42, lambda= 0.95216, k= 0.32918, x= 3.66;
 90% confidence interval for segment length: 11 +- 10)
 $M_{0.05}$ = 9.37 (x= 1.95)

of segments (>=20 residues) exceeding $M_{0.05}$: none

High scoring mixed charge segments:

score= 1.00 frequency= 0.134 (KEDR)
 score= 0.00 frequency= 0.000 (BZX)
 score= -1.00 frequency= 0.866 (LAGSVTIPNFQYHMCW)

Expected score/letter: -0.731; Average information/letter: 1.966
 Minimal length of displayed segments set to: 20

$M_{0.01}$ = 6.00 (cv= 3.79, lambda= 1.86344, k= 0.61793, x= 2.21;
 90% confidence interval for segment length: 8 +- 5)
 $M_{0.05}$ = 5.13 (x= 1.34)

of segments (>=20 residues) exceeding $M_{0.05}$: none

High scoring uncharged segments:

score= 1.00 frequency= 0.866 (LAGSVTIPNFQYHMCW)

CUCBA



BIO-SCA CENTRAL

score= 0.00 frequency= 0.000 (BZX)
 score= -8.00 frequency= 0.134 (KEDR)

Expected score/letter: -0.209; Average information/letter: 0.013
 Minimal length of displayed segments set to: 20

M_0.01= 140.63 (cv= 142.93, lambda= 0.04942, k= 0.00897, x= -2.30;
 90% confidence interval for segment length: 756 +- 748)

M_0.05= 107.65 (x= -35.28)
 ! average information < .10; too small !

C. CHARGE RUNS AND PATTERNS.

The table below shows the charge runs and patterns searched for (* stands for + or -) and the required minimum number of matches to the pattern allowing for at most 0 (lmin0), 1 (lmin1), or 2 (lmin2) mismatches or insertions/deletions (1% significance level). Occurrences are arranged in the order in which they appear in the sequence. For each run or pattern are displayed its length (number of matches) and a triplet giving the number of mismatches, insertions and deletions. 0-runs are further characterized by their composition (residues comprising more than 10% of the run).

Run count statistics are compiled for runs of lengths at least 2/3 of the minimal significant length (lmin0); given are the number and locations of such runs.

pattern	(+)	(-)	(*)	(0)	(+0)	(-0)	(*0)	(+00)	(-00)	(*00)
lmin0	3	5	6	67	8	10	12	9	13	15
lmin1	5	6	7	81	9	12	14	12	16	18
lmin2	6	8	9	90	11	14	16	13	18	20

There are no charge runs or patterns exceeding the given minimal lengths.

Run count statistics:

+ runs >= 3: 0
 - runs >= 3: 1, at 98;
 * runs >= 4: 1, at 130;
 0 runs >= 45: 0

CUCBA



BIBLIOTECA CENTRAL

----- DISTRIBUTION OF OTHER AMINO ACID TYPES

Routinely, SAPS indicates high scoring hydrophobic and transmembrane segments. The display is as described above for high scoring charge segments. The scores for the hydrophobic segments correspond to a digitized hydrophathy scale. The transmembrane scores were derived from target frequencies in putative transmembrane proteins (see the paper referred to above; note, however, that the scores used in the program have been rederived and differ from the ones given in the paper). With the -a command line flag, the user can invoke a similar analysis for other residue types. In view of the special role of cysteines for protein structure, the spacings of the cysteine residues in the sequence are displayed separately, with particular emphasis on close pairs of cysteines and distances between such pairs.

1. HIGH SCORING SEGMENTS.

High scoring hydrophobic segments:

2.00 (LVIFM) 1.00 (AGYCW) 0.00 (BZX) -2.00 (PH) -4.00 (STNQ)
 -8.00 (KEDR)

Expected score/letter: -2.485; Average information/letter: 1.229
 Minimal length of displayed segments set to: 15

M_0.01= 17.50 (cv= 11.44, lambda= 0.61765, k= 0.42563, x= 6.06;

90% confidence interval for segment length: 13 +- 7)
 M_0.05= 14.86 (x= 3.43)

of segments (>=15 residues) exceeding M_0.05: none

High scoring transmembrane segments:

5.00 (LVIF) 2.00 (AGM) 0.00 (BZX) -1.00 (YCW) -2.00 (ST)
 -6.00 (P) -8.00 (H) -10.00 (NQ) -16.00 (KR) -17.00 (ED)

Expected score/letter: -2.927; Average information/letter: 0.574
 Minimal length of displayed segments set to: 15

M_0.01= 48.28 (cv= 33.99, lambda= 0.20783, k= 0.19609, x= 14.30;
 90% confidence interval for segment length: 25 +- 18)
 M_0.05= 40.44 (x= 6.45); M_0.30= 31.11 (x= -2.88)

- 1) From 8 to 24: length= 17, score=44.00 *
 8 IFLTGLFLLS VANVALG
 L: 5(29.4%); A: 2(11.8%); G: 2(11.8%); V: 2(11.8%);
 F: 2(11.8%);
- 2) From 1156 to 1169: length= 14, score=47.00 *
 1156 GISIFIASLL LAIV
 L: 3(21.4%); A: 2(14.3%); S: 2(14.3%); I: 4(28.6%);

of segments (>=15 residues) exceeding M_0.30: 2

2. SPACINGS OF C.

HZN-28-C-57-C-6
 CAC at 94
 -22-C-17-C-59
 CC at 197 (1= 105)
 -85-C-11-C-13
 CTEC at 311 (1= 118)
 -23
 CTEC at 338 (1= 31)
 -23
 CTEC at 365 (1= 31)
 -32
 CTEC at 401 (1= 40)
 -23
 CTEC at 428 (1= 31)
 -32
 CTEC at 464 (1= 40)
 -23
 CTEC at 491 (1= 31)
 -32
 CTEC at 527 (1= 40)
 -23
 CTEC at 554 (1= 31)
 -32
 CTEC at 590 (1= 40)
 -351-C-4-C-26-C-26-C-4-C-160-COOH

CUCBA



BIBLIOTECA CENTRAL

 REPETITIVE STRUCTURES.

Repeats are indicated for two alphabets: the 20-letter amino acid alphabet, and a reduced 11-letter alphabet in which the major hydrophobics LVIF, the charged residues KR and ED, the small residues AG, the hydroxyl group residues ST, the amid group residues NQ, and the aromatics YW are treated as combined letters. For each alphabet, three classes of repeats are distinguished: separated repeats, simple tandem repeats, and periodic repeats. The separated repeats are largely non-overlapping. They are displayed in groups of matching blocks (exceeding a given core block

length of contiguous exact matches) and intervening spacer distances (which may be negative, signifying a partial overlap). The core block length in case of the amino acid alphabet is set to 4 for sequences up to 500 residues, to 5 for sequences between 500 and 2000 residues, and to 6 for longer sequences (same values increased by 4 for the reduced alphabet). Simple tandem repeats are displayed in similar layout, but separately. Sequence segments that are highly repetitive with relatively short repeats are displayed as periodic repeats.

A. SEPARATED, TANDEM, AND PERIODIC REPEATS: amino acid alphabet.

Repeat core block length: 5

Aligned matching blocks:

[211- 215] TINGI
[965- 969] TINGI

[299- 303] SSATS
[897- 901] SSATS

[303- 322] SSWSSSEVCTECTETESTSY
[330- 349] SSWSSSEVCTECTETESTST
[357- 376] SSSSSSEVCTECTETESTSY
[393- 412] SFSSSEVCTECTETESTST
[420- 439] SSWSSSEVCTECTETESTSY
[456- 475] SFSSSEVCTECTETESTST
[483- 502] SSSSSSEVCTECTETESTSY
[519- 538] SFSSSEVCTECTETESTST
[546- 565] SSWSSSEVCTECTETESTSY
[582- 601] SFSSSEVCTECTETESTST

[542- 546] YVTSS
[671- 675] YVTSS

[543- 547] VTSSS
[689- 693] VTSSS

[580- 584] TSSFS
[833- 837] TSSFS

[614- 621] TSFTASTS
[841- 847] TS_TASTS

[701- 706] SESSES
[803- 808] SESSES

[886- 892] SS_ENSAS
[1046-1054] SSDIENSAS

[937- 951]-(7)-[959- 963]
[996-1010]-(7)-[1018-1022]

CUBA



REPUBLICA CENTRAL

[937- 951] TLLITVSSCESNSCS
 [996-1010] TLLITVTSCESGVCS
 [959- 963] VSTAT
 [1018-1022] VSTAT

Simple tandem repeat:

[328- 390] see sequence above
 [391- 453] see sequence above
 [454- 516] see sequence above
 [517- 579] see sequence above
 [580- 609] see sequence above

B. SEPARATED AND TANDEM REPEATS: 11-letter reduced alphabet.

(i= LVIF; += KR; -= ED; s= AG; o= ST; n= NQ; a= YW; p= P; h= H; m= M; c= C)
 Repeat core block length: 9

Aligned matching blocks:

[302- 322] oooaooo-ico-co-o-oooo
 [329- 349] oooaooo-ico-co-o-oooo
 [356- 376] ooooooo-ico-co-o-oooo
 [392- 412] ooioooo-ico-co-o-oooo
 [419- 439] oooaooo-ico-co-o-oooo
 [455- 475] ooioooo-ico-co-o-oooo
 [482- 502] ooooooo-ico-co-o-oooo
 [518- 538] ooioooo-ico-co-o-oooo
 [545- 565] oooaooo-ico-co-o-oooo
 [581- 601] ooioooo-ico-co-o-oooo

Simple tandem repeat:

[333- 395] see sequence above
 [396- 458] see sequence above
 [459- 521] see sequence above
 [522- 584] see sequence above
 [585- 610] see sequence above

CUCBA



BIBLIOTECA CENTRAL

MULTIPLETS.

Multiplets refer to homooligopeptides of any length (e.g., A₂, Q₇, etc.);
 altplets refer to reiterations of two different residues (e.g., RG,
 EAEAEA, etc.). The multiplet composition of the protein sequence is
 evaluated for both the amino acid and the charge alphabet. (High Aggre-
 gate altplet counts are evaluated only for the charge alphabet. The multi-
 plet sequence is displayed whenever the total multiplet count of the
 sequence falls outside the expected range (i.e., beyond 3 standard devia-
 tions of the mean). Printed are also the histogram of the spacings between
 consecutive multiplets (differences between starting positions) as well as
 clusters of multiplets (multiplet clusters are determined in the same way
 as charge clusters are determined; the binomial test is applied to a
 compressed sequence over the alphabet {M,S}, where M signifies a multiplet
 and S signifies a singlet; i.e., the amino acid sequence AADFFFGHRR... is
 translated as MSMSSMS..., and the binomial cluster test is applied to the
 latter sequence). Multiplets and altplets of specific residue content that
 individually show an unusually high count are indicated, and the positions
 of all multiplets exceeding a minimum length of 5 residues are shown.

A. AMINO ACID ALPHABET.

- Total number of amino acid multiplets: 106 (Expected range: 78--139)
- Histogram of spacings between consecutive amino acid multiplets:
(1-5) 42 (6-10) 31 (11-20) 21 (>=21) 13
- Clusters of amino acid multiplets (cmin = 14/30 or 19/45 or 22/60): none
- Significant specific amino acid altplet counts:
Letters Observed (Critical number)
VY 19 (18)
at 243 (1= 2) 272 (1= 2) 322 (1= 2) 326 (1= 2) 353 (1= 2)
376 (1= 2) 380 (1= 2) 416 (1= 2) 439 (1= 2) 443 (1= 2)
479 (1= 2) 502 (1= 2) 506 (1= 2) 542 (1= 2) 565 (1= 2)
569 (1= 2) 671 (1= 2) 923 (1= 2) 1031 (1= 2)
- Long amino acid multiplets (>= 5; Letter/Length/Position):
S/7/356 S/7/482

B. CHARGE ALPHABET.

- Total number of charge multiplets: 10 (Expected range: 1-- 22)
3 +plets (f+: 3.6%), 7 -plets (f-: 9.8%)
Total number of charge altplets: 9 (Critical number: 19)
- Histogram of spacings between consecutive charge multiplets:
(1-5) 1 (6-10) 1 (11-20) 2 (>=21) 7

PERIODICITY ANALYSIS.

The program identifies periodic elements of periods between 1 and 10 for the amino acid alphabet, for the charge alphabet, and for a hydrophobicity alphabet. Each periodic element consists of an error-free core pattern (of length at least 4 for the amino acid alphabet, 5 for the charge alphabet, and 6 for the hydrophobicity alphabet) which is extended allowing for errors. The numbers of errors are given for each position in the consensus of a periodic pattern involving more than one letter. The displayed periodic patterns would generally not be statistically significant but are listed for the sake of a general interactive appraisal of the sequence. Periodicities of exceptionally high copy number are indicated with a !-mark.

A. AMINO ACID ALPHABET (core: 4; !-core: 5)

Location	Period	Element	Copies	Core	Errors
329- 336	2	S.	4	4	0
356- 362	1	S	7	7 !	0
392- 398	1	S	6	4	1
419- 426	2	S.	4	4	0
455- 461	1	S	6	4	1
482- 488	1	S	7	7 !	0
518- 524	1	S	6	4	1
545- 552	2	S.	4	4	0
581- 587	1	S	6	4	1
596- 623	7	T.....	4	4	0
614- 625	3	T..	4	4	0
691- 710	5	S...S	4	4	0
742- 761	5	TS..S	4	4	/0/1/././1/
755- 790	9	SS.S.....	4	4	/0/1/./1/./././././
808- 839	8	S.....	4	4	0
862- 903	6	S.....	6	4	1
900- 915	4	TS..	4	4	/0/1/././
943- 958	4	S...	4	4	0
1077-1092	4	T...	4	4	0
1130-1145	4	S...	4	4	0

B. CHARGE ALPHABET ({+= KR; -= ED; 0}; core: 5; !-core: 6)

CUCBA



BIBLIOTECA CENTRAL

and HYDROPHOBICITY ALPHABET ({*= KRED; i= LVIF; 0}; core: 6; !-core: 8)

Location Period Element Copies Core Errors

There are no periodicities of the prescribed length.

SPACING ANALYSIS.

The spacings between consecutive residues of the same type (all 20 amino acids, + and - charge, and combined charge *) are evaluated for significantly large or small maximal and minimal spacings. The output is ordered by the beginning point of the significant spacing. Entries are identified by the residue type, spacing (number of amino acids between the identified positions), rank of the displayed spacing (e.g., 50 alanines in the sequence induce 51 spacings, ranked by decreasing length from 1 to 51), and p-value (probability of exceeding the displayed spacing). A maximal spacing with p-value 0.01 or less is considered significantly large; a maximal spacing with p-value 0.99 or larger is considered significantly small. Similarly, a minimal spacing with p-value 0.99 or larger is considered significantly small, and a minimal spacing with p-value 0.01 or less is considered significantly large (excluding doublets). If the first maximal spacing (rank 1) of a residue is significantly large or small, then also the second maximal spacing (rank 2) is evaluated. Large maximal and small minimal spacings indicate clustering effects, whereas small maximal and large minimal spacings indicate excessive evenness in the distribution of the residues.


Location (Quartile)	Spacing	Rank	P-value	Interpretation
17- 47 (1.)	S(30)S	2 of 284	0.0014	large 2. maximal spacing
146- 184 (1.)	S(38)S	1 of 284	0.0062	large 1. maximal spacing
241- 665 (2.)	K(424)K	1 of 32	0.0000	large maximal spacing
242- 661 (2.)	I(419)I	1 of 43	0.0000	large maximal spacing
259- 627 (2.)	L(368)L	1 of 39	0.0000	large maximal spacing
271- 611 (2.)	G(340)G	1 of 39	0.0001	large maximal spacing
278- 631 (2.)	D(353)D	1 of 31	0.0005	large 1. maximal spacing
295- 665 (2.)	+(370)+	1 of 43	0.0000	large 1. maximal spacing
593- 945 (3.)	C(352)C	1 of 36	0.0001	large 1. maximal spacing
604- 649 (3.)	P(45)P	2 of 50	1.0000	small 2. maximal spacing
750- 910 (3.)	D(160)D	2 of 31	0.0265	large 2. maximal spacing
925- 989 (4.)	+(64)+	2 of 43	0.9794	small 2. maximal spacing
931- 978 (4.)	P(47)P	1 of 50	1.0000	large 1. maximal spacing
1009-1170 (4.)	C(161)C	2 of 36	0.0065	large 2. maximal spacing

CUCBA




BIBLIOTECA CENTRAL


V. Matriz de puntos de las 86 secuencias de aminoácidos de los tres genomas microbianos. *Saccharomyces cerevisiae*




>CP-171388 gi|171388 (M36L10) DDR48 stress protein [Saccharomyces cerevisiae]




>CP-172528 gi|172528 (M16L5) S1 protein [Saccharomyces cerevisiae]




>CP-2245320 gi|11360451|gnl|PI01c245920 (273256) ORF YLR084c [Saccharomyces cerevisiae]; gi|1256886 (U53880) YLR041cp [Saccharomyces cerevisiae]




>CP-2251944 gi|11420104|gnl|PI01e251944 (274917) ORF YOR009w [Saccharomyces cerevisiae]; gi|1151005 (U43491) hypothetical protein [Saccharomyces cerevisiae]




>SW-NSR1 YEAST SW:NSR1_YEAST P27476 saccharomyces cerevisiae (baker's yeast). Nuclear localization sequence binding protein 1p61. 10/96;




>SW-NUS7 YEAST SW:NUS7_YEAST P48837 saccharomyces cerevisiae (baker's yeast). Nucleoporin nup57 (nuclear pore protein nup57). 10/96;




>SW-PIR3 YEAST SW:PIR3_YEAST Q03180 saccharomyces cerevisiae (baker's yeast). p13 protein precursor. 11/95; gi104129|gnl|PIR3|d1003392




>SW-PP22 YEAST SW:PP22_YEAST P33329 saccharomyces cerevisiae (baker's yeast). serine/threonine protein phosphatase pp-22 (ec 3.1.3.15). 10/96




>PIR-961977 PIR:961977 Rml protein - yeast (Saccharomyces cerevisiae);
qi1030721(gnl)PID:q1010303 (D63340) Rml (Saccharomyces cerevisiae);




>PIR-961046 PIR:961046 Rml protein - yeast (Saccharomyces cerevisiae);
qi11431266(gnl)PID:q232076 (E74215) Rml (Saccharomyces




>PIR-577699 PIR:577699 inner cell wall mannoprotein ICP - yeast
(Saccharomyces cerevisiae)




>SW-3201 YEAST SW:S201 YEAST Q01389 saccharomyces cerevisiae (baker's
yeast). sed1 protein precursor. 10/96; q11491343(gnl)PID:q53329




>SW-SR40_YEAST SW:SR40_YEAST P32583 saccharomyces cerevisiae (baker's yeast). suppressor protein srp40. 6/94; PIR:S36170 SR40 protein - yeast [Saccharomyces cerevisiae]; gi1486581 (E293171 ORF YKR092c




>SW-SSN6_YEAST SW:SSN6_YEAST P14922 saccharomyces cerevisiae (baker's yeast). glucose repression modulator protein. 2/95; gi1172726 (M17826) SSN6 protein [Saccharomyces cerevisiae]; gi1171350 (U29440)




>SW-USO1_YEAST SW:USO1_YEAST P25386 saccharomyces cerevisiae (baker's yeast). intracellular protein transport protein usol. 10/96; gi14778 (X54378) Usol protein [Saccharomyces cerevisiae]




>SW-YAG3_YEAST SW:YAG3_YEAST P39712 saccharomyces cerevisiae (baker's yeast). hypothetical 138.1 kd protein in flo9-gdh3 intergenic precursor. 2/96; gi758410 (U12980) FLO1 homolog [Saccharomyces cere




>SW-YCC8_YEAST SW:YCC8_YEAST P25367 *saccharomyces cerevisiae* (baker's yeast). Hypothetical 42.5 kd protein in btk1-fus1 intergenic region.




>SW-YCC9_YEAST SW:YCC9_YEAST P23653 *saccharomyces cerevisiae* (baker's yeast). Hypothetical 155.0 kd protein in abp1 3' region. 10/96




>SW-YIR7_YEAST SW:YIR7_YEAST P10414 *saccharomyces cerevisiae* (baker's yeast). Hypothetical 197.5 kd protein in sac2 5' region. 11/95; gi1603898 (247047) unknown [*Saccharomyces cerevisiae*]; gi1600799 (2




>SW-YGIF_YEAST SW:YGIFP_YEAST P53214 *saccharomyces cerevisiae* (baker's yeast). Hypothetical 57.5 kd protein in vma7-rps31a intergenic region.




>SW-YG3R_YEAST SW:YG3R_YEAST P33288 saccharomyces cerevisiae (baker's yeast). Hypothetical 22.2 kd protein in nsr1-ctf4631 intergenic region.




>SW-YH11_YEAST SW:YH11_YEAST P28894 saccharomyces cerevisiae (baker's yeast). Hypothetical 112.0 kd protein in twt1-pho12 intergenic region precursor. 2/99; gi458919 (U00029) Thr121pp (Saccharomyces)




>SW-YI181_YEAST SW:YI181_YEAST P40552 saccharomyces cerevisiae (baker's yeast). Hypothetical 26.3 kd protein in pdr11-faa3 intergenic region.




>SW-YJ9P_YEAST SW:YJ9P_YEAST P17179 saccharomyces cerevisiae (baker's yeast). Hypothetical 118.4 kd protein in rps7b-dal5 intergenic region precursor. 10/94; q11015903 (349451) ORF YJ9P51c (Saccharom




>SW-YKB2 YEAST SW:YKB2 YEAST P54178 methanomyces ozonellae (baker's yeast). hypothetical 122.9 kd protein in airt 2' region sequence.
1/74; PIR:15812; electroblin protein Puri cloning YKBF4 - yea




>SW-YKBF4 YEAST SW:YKBF4 YEAST P15732 saccharomyces cerevisiae (baker's yeast). hypothetical 84.0 kd protein in omp120-csf1 intergenic region.
2/35; PIR:137874 glutamine-rich protein YKBF4c - yeast




>SW-YNJ1 YEAST SW:YNJ1 YEAST P53935 saccharomyces cerevisiae (baker's yeast). hypothetical 112.5 kd protein in yps33-rho2 intergenic region.




>SW-YNR6 YEAST SW:YNR6 YEAST P53082 saccharomyces cerevisiae (baker's yeast). hypothetical 67.4 kd protein in yps3-psd1 intergenic region.




>SW-NM1L_YEAST SW:NM1L_YEAST F11746 saccharomyces cerevisiae (baker's yeast). ubermann receptor transcription factor (gpa/prtf protein).




>SW-MSB2_YEAST SW:MSB2_YEAST F32334 saccharomyces cerevisiae (baker's yeast). msb2 protein (multiplicity suppression of a budding defect 21).




>SW-N100_YEAST SW:N100_YEAST Q02629 saccharomyces cerevisiae (baker's yeast). nucleoporin nup100/nsp100 (nuclear pore protein nup100/nsp100).



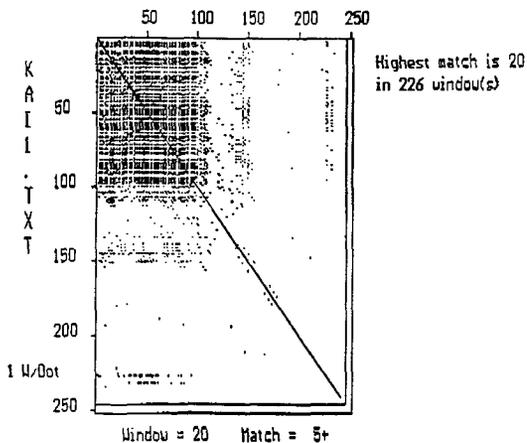
>SW-N145_YEAST SW:N145_YEAST P19687 saccharomyces cerevisiae (baker's yeast). nucleoporin nup145 (nuclear pore protein nup145). 10/95;




>E312897 g11945397(gail1 P1D) (312946) ORF YOR159c
[Saccharomyces cerevisiae]




>SW-HKRI_YEAST SW:HKRI_YEAST P41809 saccharomyces cerevisiae (baker's yeast). haemolysin killer toxin-resistant protein 1 precursor. 10/96: g1545669(hbs144411) (569101) Hkr1p [Saccharomyces cerevisiae]




>SW-KAIL_YEAST SW:KAIL_YEAST P41944 saccharomyces cerevisiae (baker's yeast). protein kinase a interference protein (kail protein). 10/96




>SW-KFD3_YEAST SW:KFD3_YEAST P43565 saccharomyces cerevisiae (baker's yeast). probable serine/threonine-protein kinase yf1033c (cc 2.7.1.-). 10/96




>Q2-E25229: gi|14199671|gml|P1D1e252294 (874847) ORF YOL105c
[Saccharomyces cerevisiae]; gi|663247 (240149) similarity with H.
polyorpha hypothetical protein in LAW2 region [Saccharomyces cerevisiae]




>G2-E252336 gi|1420189|gml|P1D1e252336 (874961) ORF YOR053v
[Saccharomyces cerevisiae]; gi|12104865|gml|P1D1e234099 (870678) TOR29-04




GI-E252990 gi|1431020|gml|P1D1e252990 (874085) ORF YDL037c [Saccharomyces
cerevisiae]; gi|1279679|gml|P1D1e237295 (871781) unknown [Saccharomyces




>G2-E308403 gi|1393280|gml|P1D1e308403 (874105) ORF YDL058w
[Saccharomyces cerevisiae]




>CP-8190152 gi|1174221|gnl|FID|e190152 (X89715) Adp1001 gene product
[Saccharomyces cerevisiae]




>CP-e236826 gi|1314096|gnl|FID|e236826 (371255) unknown [Saccharomyces
cerevisiae]; gi|1809587|449274) unknown [Saccharomyces cerevisiae]




>CP-e239064 gi|119132|gnl|FID|e119132 (23474) putative ORF
[Saccharomyces cerevisiae]




>CP-e245919 gi|1360284|gnl|FID|e245919 (173172) ORF YLL067c
[Saccharomyces cerevisiae]




>SW-ANXH_YEAST SW-ANXH_YEAST P06610 saccharomyces cerevisiae (baker's yeast). glucosylase s1/2 precursor (ec 3.2.1.3) (glucan 1,4-alpha-glucosidase) (1,4-alpha-d-glucan glucohydrolase). 2/95; PTR-J




>SW-CHIT_YEAST SW-CHIT_YEAST P29029 saccharomyces cerevisiae (baker's yeast). endochitinase* Precursor (ec 3.2.1.14). 10/86; gi1596043 [U17243] Pribchitnase 2 (Saccharomyces cerevisiae)




>SP-D1020704 gi120779001|gn1|PID|d1020704 (A5003521) Flocculin [Saccharomyces cerevisiae]




>SP-DNA8_YEAST SW-DNA8_YEAST P18899 saccharomyces cerevisiae (baker's yeast). dna8 stress protein (dna damage-responsive protein 8) (ddrp 8)




>GP-899399 gi|899399 (Z50046) Mump1 [Saccharomyces cerevisiae]




>GE-927801 gi|927801 (U33057) Ydr534cp; CAI: 0.26 [Saccharomyces cerevisiae]




>SW-AGAL YEAST SW:AGAL YEAST P32323 saccharomyces cerevisiae (baker's yeast). a-xyglutinin attachment subunit precursor. 10/96;




>PIR-ALBYG PIR:ALBYG glucan 1,4-alpha-glucosidase (DC 3.2.1.3) precursor




>62-544510 gi|544510 (U14913) YL194cp [Saccharomyces cerevisiae]




>62-694125 gi|694125 (L28920) 1890bp repeat elements added, composed of 14 repeats of 133bp repeat element from Mitari, J. et al., Yeast 10, 211-225 (1994) Molecular cloning and analysis of the yeast




>62-871535 gi|871535 (X87806) verprolin [Saccharomyces cerevisiae]




62-85443 gi|85443 (Z49808) Bdr4p [Saccharomyces cerevisiae];
qj|685013|bbs|155542 (S73336) F92=flocculent specific protein




>G1-2252970 g11430953|gpl|DID1a252970 (274053) ORF YDL005c
[Saccharomyces cerevisiae]; g11683692 (848432) unknown [Saccharomyces




>G1-311109 g1311109 (L16900) Intrastand crosslink recognition protein
[Saccharomyces cerevisiae]




>G1-396560 g1396560 (X74428) serine-rich protein [Saccharomyces
cerevisiae]



>G1-4076 g11076 (215036) nuclear pore complex protein NP2116
[Saccharomyces cerevisiae]




>SN-YNB018 YEAST SW:YNB018 YEAST F53862 *Saccharomyces cerevisiae* (baker's yeast). Hypothetical 28.6 kd protein in urc2-ssu72 intergenic region




AKIB OR HI0056.


Haemophilus influenzae



ET0119.




FOHS OR HI0251.




Highest match is 20
in 222 window(s)

Window = 20 Match = 5+
HI0264.




Highest match is 20
in 177 window(s)

Window = 20 Match = 5+
HI0363.







Highest match is 20
in 240 window(s)



Window = 20 Match = 5+
HI0999.





Highest match is 20
in 161 window(s)





Window = 20 Match = 5+
HI0915.










Methanococcus jannaschii










Highest match is 20
in 229 window(s)

Window = 20 Match = 5+
(Space (Fast) analysis)

>4J0124 type Y restriction enzyme EGAD:28293



Highest match is 20
in 231 window(s)

Window = 20 Match = 5+

>J0487 phenylalanine-tRNA synthetase subunit alpha SP:715615

CUCEA



BIBLIOTECA CENTRAL

8. GLOSARIO

1. Abreviaciones de los 20 aminoácidos.

Alanina (**A**).
 Arginina (**R**).
 Asparagina (**N**).
 Ácido aspártico (**D**).
 Cisteína (**C**).
 Glutamina (**Q**).
 Ácido glutámico (**E**).
 Glicina (**G**).
 Histidina (**H**).
 Isoleucina (**I**).
 Leucina (**L**).
 Lisina (**K**).
 Metionina (**M**).
 Fenilalanina (**F**).
 Prolina (**P**).
 Serina (**S**).
 Treonina (**T**).
 Triptofano (**W**).
 Tirosina (**Y**).
 Valina (**V**).

CUEVA



BIBLIOTECA CENTRAL

2. Anonymous FTP: Permite tener acceso a información que se encuentra en internet para el dominio público basándose en una clave a la cual se le llama anonymous.
3. FTP: (File Transfer Protocol). Es un protocolo para la transferencia de archivos, que permite obtener o hacer copias de archivos hacia una computadora remota en internet.
4. Shell Unix: Es un programa en lenguaje Unix, este se encarga de leer los comandos que inserta el usuario y los interpreta como requerimientos para ejecutar ciertos programas que sean requeridos.
5. Turnover: Mecanismos que causan continuas fluctuaciones en el número de copias del DNA (variando en extensión desde dos a miles de nucleótidos), estos mecanismos pueden actuar simultáneamente en regiones del DNA.
6. Desigual crossing-over: Describe un evento de recombinación en el cual los dos sitios de recombinación, se sitúan en regiones no identificadas en las dos moléculas de DNA parental.

CUCBA



BIBLIOTECA CENTRAL

*"La muerte es en la vida igual que el nacer;
como el andar está lo mismo en alzar el pie que en volverlo a la tierra".*
Tagore.