



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

---

---

INSTITUTO DE BIOTECNOLOGÍA

**“La evolución de la red de regulación transcripcional en  
bacterias es extremadamente flexible”**

T E S I S

Que para obtener el grado de

M A E S T R O E N C I E N C I A S


Presenta

**BIÓL. IRMA LOZADA CHÁVEZ**

Director de tesis:

**DR. PEDRO JULIO COLLADO VIDES**

2 0 0 6





**UNAM – Dirección General de Bibliotecas**

**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (Méjico).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

**Este proyecto se desarrolló en el laboratorio de Genómica Computacional  
del Centro de Ciencias Genómicas de la UNAM**



**Asesorado institucionalmente por:**

Dr. Pedro Julio Collado Vides	CCG
Dr. Ernesto Pérez Rueda	IBT
Dr. Alejandro Garcíarrubio Granados	IBT

**Evaluado para obtención de grado  
por el comité de sinodales:**

Dr. Enrique Merino Pérez	Presidente
Dr. Pedro Julio Collado Vides	Secretario
Dr. Arturo Carlos II Becerra Bracho	Vocal
Dr. Ernesto Pérez Rueda	Suplente
Dr. Guillermo Gosset Lagarda	Suplente

**Asesorado académicamente de  
forma externa por:**

Candidato a doctor Juan Javier Díaz Mejía	A lo largo de todo el proyecto
Dr. Bruno Contreras Moreira	En la revisión crítica del
artículo	
M.C. Sarath Chandra Janga	En la estadística para redes

Con fondos del programa de becas CONACyT, expediente número 185993.  
Así como con un apoyo post-beca CONACyT derivado de los recursos del laboratorio de Genómica  
Computacional del CCG de la UNAM,  
de donde el Dr. Pedro Julio Collado Vides es Jefe de Grupo.

*Esta tesis está dedicada a  
Alejandro Nabor Lozada Chávez,  
Ana María Chávez Morales,  
Nabor Lozada Guerrero,  
y  
a mi muy amada Universidad Nacional Autónoma de México  
(a quién debo mi felicidad académica)*

## Agradecimientos:

Para quienes tengan antecedentes de la tesis de licenciatura, verán que mi agradecimiento hacia ustedes, no ha sido menor o diferente, sólo he incrementado mi deuda y mi fortuna por su amistad y apoyo.

Quiero expresar primeramente mi total agradecimiento a mi hermano **Alejandro** porque ha sido mi familia y mi mejor amigo desde que han sido necesarios, porque me ha impulsado siempre a esperar más de mí y porque la fortaleza y lo bueno que pueda tener yo como persona se lo debo principalmente a él.

Deseo agradecer especialmente a **Julio Collado** por haberme permitido trabajar dentro de su excelente grupo de trabajo, por haberme apoyado económico en el desarrollo, culminación y difusión (congresos) de esta tesis; pero sobretodo por su amistad y porque me ha enseñado, de muchas formas, que nunca es demasiado en cuanto a aprender y a concebir proyectos se trata.

Así mismo, quiero agradecer a **Arturo Becerra** y a **Luis Delaye** por la relación académica que tenemos, porque siempre han sabido guiarme sobre “el buen camino” en los tantos problemas que acogen al estudio de la evolución temprana de la vida. Les agradezco muy especialmente por la amistad que tenemos y porque siempre han creído en mí.

Agradezco a **Sandra Ramírez** por mantener la confianza, la voluntad, las ilusiones y la disponibilidad para desarrollar conmigo amistad, trabajos de investigación y de divulgación científicos. Porque Sandra representa el inicio de una nueva generación de investigadores en México que, en el área del origen de la vida, están dispuestos a abordar las preguntas necesarias, por muy difíciles y ambiciosas que parezcan, para generar propuestas en un ambiente científico abierto e interdisciplinario. Esto representa gran admiración y motivación para mis próximos objetivos académicos.

No tengo palabras para agradecer a **Javier Díaz** todo el apoyo académico que me ha brindado desde que me incursioné en la ciencia. Le agradezco que comparta conmigo su experiencia en la dureza, formalidad, pasión, intuición y regocijo que trae la ciencia cada día a las personas que como él y como yo tratamos de ejercerla. Mi calidad académica, en el más amplio sentido de la palabra, se debe a su asesoría y a su ejemplo. Muy especialmente deseo agradecer su amistad, porque de todas, la nuestra ha sido la más probada, la más compleja y la más incierta, pero definitivamente también ha sido una de las más importantes en mi vida.

Quiero agradecer a **Bruno Contreras** por su amistad, su apoyo y sumo ingenio oculto discretamente por su sencillez, porque su humildad me ha dado otro ejemplo de la felicidad obtenida por la sabiduría y la naturaleza humana.

Por otra parte, le agradezco a **Ernesto Pérez Rueda** por su asesoría académica, siempre muy acertada, y muy enfáticamente por su amistad.

Les agradezco a mis compañeros y amigos del laboratorio: (¡las chicas!) **Concepción Hernández**, Socorro Gama, **Verónica Jiménez**, Heladia Salgado, **Mónica Peñaloza**, **Fabiola Sánchez**, Lucia López, Irma Martínez; (¡los chicos!) Cei Abreu, Bruno Contreras, Martín Peralta, Carlos Rodríguez, Juan Segura, Luis Treviño, César Bonavides, Edgar Díaz, Sarath Chandra, Luis Muñiz, Alberto Santos, Julio Freyre, **Víctor del Moral**, **Romualdo Zayas**, por su apoyo académico y personal durante mi estancia en el laboratorio. Por compartir juntos, con igual diversión, los días de trabajo y los de festejo, logrando que me sintiera como en una gran familia. Extrañaré sobremanera este ambiente de trabajo. Particularmente quiero agradecer a **Concepción Hernández**, **Mónica Peñaloza** y a **Heladia Salgado** todo su apoyo incondicional en los momentos críticos, ¡que fueron muchos!

Agradezco a mi ya inseparable parte artística y humanista: **Tania Cabagne**, **Lucelina Nunes** y **Alberto Cabañas**, por ser mis amigos bajo historias de vida muy parecidas, porque me ayudan a explotar y mantener al artista que llevo dentro, lo cual ha hecho sentirme humanamente completa. Pero sobretodo, por compartir conmigo invaluables experiencias, secretos y una percepción de la vida.

Quiero agradecer a mis amigos: **Cynthia**, **Mónica Araujo**, **Alma Mendoza**, **Lilia Montoya**, **Lidia Leal**, **Maribel Hernández**, **Woyteck**, **Sarah Chandra**, **Ricardo Menchaca**, **Cristhian Ávila**, **Mónica Peñaloza**, **Cristhian Torres**, **Leticia Ortega**, **Guillermo Quevedo**, **Alejandro Carbajal**, con quienes comparto ciencia, juventud y muy gratos momentos que llenan mi vida de forma muy peculiar.

Le agradezco a **Mathieu Deschênes** todo su amor, los momentos invaluables que hemos compartido juntos, y por haber generado un espacio de felicidad en base a la honestidad, al entendimiento y al apoyo mútuos que permitieron la adaptación de nuestros diferentes estilos de vida y, con ello, hacer de mí una mejor persona.

Deseo agradecer a **Concepción**, **Daniel**, **Abraham**, **Moisés** y **Esaú**, a quienes amo desde que entraron en mi vida, y quienes más se han percatado del tiempo que he invertido en mi desarrollo profesional.

Muy especialmente, agradezco a quienes considero como mis familias y mis amigos, la **familia Araujo** y la **familia Díaz** que siempre han tenido un espacio especial entre su gente para mí.

Finalmente quiero agradecer a mi padre, **Nabor Lozada**, y a mi madre, **Ana María Chávez**, por mostrarme lo difícil que es la vida, así como la fortaleza que una persona puede tener cuando parece que todo está perdido. Les agradezco porque sin importar circunstancias o motivos me concibieron y cuidaron de mí bajo una familia los años que recuerdo como los más completos y felices de mi vida, mi niñez. Pero sobretodo, quiero agradecerles por buscar conmigo, siempre que es posible y necesario, los puentes que nos permitan recuperar todo el tiempo perdido.

Mi mayor agradecimiento para la **Universidad Nacional Autónoma de México** porque me ha brindado las oportunidades necesarias para generar una expectativa de la vida, a través del conocimiento, lo cual contribuye en gran medida a mi felicidad cotidiana.

**“La evolución de la red de regulación transcripcional en bacterias es extremadamente flexible”**

*Por Irma Lozada-Chávez*

## ÍNDICE

<b>RESUMEN</b>	
<b>INTRODUCCIÓN</b>	(código para figuras, esquemas y tablas: I)
I. Generalidades sobre la regulación transcripcional en bacterias.	2
II. Componentes y estructura de la TRN.	4
III. El método Regulog para la transferencia de las interacciones regulatorias.	7
IV. Comparación general de los modelos: <i>Escherichia coli</i> vs <i>Bacillus subtilis</i> .	11
<b>OBJETIVOS E HIPÓTESIS.</b>	13
<b>MATERIALES Y MÉTODOS</b>	(código para figuras, esquemas y tablas: M)
A) Colección de proteomas.	14
B) Datos de las interacciones proteína-DNA.	12
C) Detección de TFs y TGs potenciales en diversos genomas.	12
D) Tratamiento de los datos.	17
E) Conservación de ortólogos.	17
F) Persistencia de los pares de ortólogos de TF-TG a través de los genomas.	17
G) Obtención de los valores de corte ( <i>thresholds</i> ) para identificar las categorías de los pares de interacciones TF-TG co-ocurriendo.	19
H) Análisis estadísticos para la persistencia de las interacciones.	19
I) Regulones conservados.	20
J) Interacciones regulatorias ancestrales.	20
<b>RESULTADOS Y DISCUSIÓN</b>	(código para figuras, esquemas y tablas: R)
1. Conservación de los componentes de las TRNs (TFs y TGs) entre las especies.	22
2. Evolución de los Reguladores Globales a través de las especies bacterianas.	24
3. Evolución de pares TF-TG en TRNs.	26
4. Conservación de los regulones e interacciones antiguas de las TRNs en Bacteria.	28
<b>DISCUSIÓN GENERAL Y CONCLUSIONES</b>	31
<b>REFERENCIAS</b>	33
<b>ARTÍCULO CIENTÍFICO DEL PROYECTO</b>	
Aceptado para su publicación en la revista científica con tiraje internacional <i>Nucleic Acids Research</i>	
<b>ANEXOS</b>	( <i>Supplementary material del artículo</i> )
1. Tabla de características de los 204 genomas utilizados en este estudio.	1
2A. Tabla de los regulones conocidos de <i>E. coli</i> utilizados como referencia.	7
2B. Tabla de los regulones conocidos de <i>B. subtilis</i> utilizados como referencia.	
3A. Tabla de los pares de genes de las rutas metabólicas de la base de datos KEGG en <i>E. coli</i> y <i>B. subtilis</i> .	20
3B. Valores estadísticos obtenidos para 3A en <b>Métodos-G</b> .	
4A. Esquema de aleatorización y estadística de redes utilizada en <b>Métodos-H</b> .	21
4B. Análisis de la distribución normal de 4A para la obtención los Z-scores y p-values en <b>Métodos-H</b> .	
5. Información sobre las interacciones ancestrales.	23
6A. Réplica de Fig. R1A de la TRN de <i>E. coli</i> en 204 genomas.	26
6B. Réplica de Fig. R1B de la TRN de <i>B. subtilis</i> en 204 genomas.	
8A. Ejemplos reportados sobre la función de los ortólogos de la familia CRP-FNR.	28
8B. Ejemplos reportados sobre la función de los ortólogos de la familia LRP.	
8C. Función de CRP ( <i>E. coli</i> ) y de CcpA ( <i>B. subtilis</i> ) en la regulación global de las rutas centrales del catabolismo de carbono.	
<b>Página web del proyecto:</b> <a href="http://www.ccg.unam.mx/Computational_Genomics/TRNS/conservation/">http://www.ccg.unam.mx/Computational_Genomics/TRNS/conservation/</a>	

## RESUMEN

A través de millones de años, la estructura y complejidad de la Red Regulatoria Transcripcional (TRN – Transcriptional Regulatory Network) en las bacterias ha sido cambiada y reorganizada para permitir a estos organismos adaptarse a casi cualquier nicho ecológico sobre la Tierra. Con el fin de entender la flexibilidad evolutiva de las TRNs en bacterias, estudiamos la conservación de las TRNs de los dos organismos modelo *Escherichia coli K12* y *Bacillus subtilis* por medio de herramientas bioinformáticas para detectar sus contrapartes en los genomas completos de Bacteria, Archaea y Eukarya a tres diferentes niveles: componentes de la TRN, pares de interacciones y regulones. Encontramos que los factores de transcripción (TF) se pierden mucho más rápido que los genes regulados (TG) a través de los *phyla*<sup>1</sup>. Mostramos que los reguladores globales (GR) están pobremente conservados a través del espectro filogenético. Más aún, de los TF's detectados, notamos que son menores las interacciones equivalentes que éstos guardan en las especies distintas a los modelos. De ahí, que los TFs podrían ser los principales elementos responsables para la plasticidad y *evolucionabilidad*<sup>2</sup> de las TRNs. También encontramos que hay sólo una pequeña fracción de interacciones regulatorias transcripcionales conservadas significativamente entre los diferentes *phyla* bacterianos y, que existe una restricción sobre los elementos de la interacción para co-ocurrir. Finalmente, nuestros resultados sugieren que la mayoría de los regulones en bacterias han cambiado rápidamente con la distancia filogenética, lo cual implica un nivel más alto de jerarquía en la flexibilidad de las TRNs. Desde nuestro análisis comparativo, generamos la hipótesis de que la regulación transcripcional de ciertos procesos celulares esenciales, tales como la síntesis de arginina, biotina y ribosa, transporte de aminoácidos y hierro, disponibilidad de fosfato, procesos de replicación y la respuesta a SOS han sido bien conservados en la evolución. A partir de este trabajo, es posible inferir que la regulación transcripcional es más flexible que el componente genético de los organismos y que su estructura juega un papel importante en la adaptación fenotípica.


---

<sup>1</sup> *Phylum* (1). (Plural: *phyla*) Es un taxón usado en la clasificación de la vida como primera división de un reino, de mayor rango que una clase. Un *phyla* representa grandes grupos de organismos generalmente aceptados con ciertos rasgos evolutivos.

<sup>2</sup> *Evolucionabilidad* (2). (*Evolvability*) Es una capacidad del genotipo para generar variación fenotípica heredable. Esta capacidad tiene dos componentes: **i**) reducir la letalidad potencial de mutaciones y **ii**) reducir el número de mutaciones necesitadas para producir rasgos novedosos fenotípicamente. La *evolvability* puede haber sido seleccionada generalmente en el transcurso de la selección para robustecer procesos flexibles convenientes para el desarrollo complejo y fisiología, y específicamente seleccionada en linajes sometidos a radiaciones repetidas.

# INTRODUCCIÓN

La **evolución** de los organismos está dada por la variación y la selección de sus componentes, procesos y estructura a través del tiempo. Siendo un componente y proceso básico del organismo, la **regulación transcripcional** juega un papel prominente en la expresión de la información genética. Su función primaria es permitir que la célula responda, controle y se adapte en respuesta a cambios intracelulares y extracelulares, tales como el estado nutricional, la división celular, la esporulación (cuando aplica), así como varios estreses. Una importante idea que surge con los trabajos de Michael A. Savageau y Stuart A. Kauffman desde los años 70's es que la regulación transcripcional puede ser vista como una red compleja de interacciones entre diversos tipos de moléculas, tales como proteínas, RNA, DNA y metabolitos (4-12) [ver Figura I1]. A partir de estas redes, podemos entender niveles jerárquicos más altos en la organización de la información y procesos biológicos, tal como en este caso de la regulación transcripcional. En este trabajo, tratamos de valorar la evolución de la estructura y flexibilidad de la **Red de Regulación Transcripcional (TRN – Transcriptional Regulatory Network)**, por medio de un análisis comparativo a través de los genomas completos de los organismos desde tres distintos niveles: componentes individuales de la TRN, pares de interacciones regulatorias y regulones.



**Figura I1. Representación de la organización de la información y procesos celulares en la naturaleza (13).** En la base de la pirámide se muestra la dirección de la expresión genética: el genoma, transcriptoma, proteoma y metaboloma (**nivel 1**), que a su vez proporciona la especificidad de los organismos. Pueden conseguirse revelaciones sobre la lógica de la organización celular cuando observamos a la célula como una red compleja, en la cual los componentes son conectados a través de conexiones funcionales. En el nivel más bajo de estas redes, los componentes forman motivos genético-regulatorios o rutas metabólicas (**nivel 2**), los cuales

llegan a ser parte de los bloques constitutivos de los módulos funcionales (**nivel 3**). Estos módulos son agrupados, generando una arquitectura jerárquica “libre de escala” (definida posteriormente en este trabajo) (**nivel 4**). Este último nivel de organización nos sugiere que se pueden encontrar principios de organización universales y aplicar a la naturaleza.

## I. Generalidades sobre la regulación transcripcional en bacterias.


La **transcripción** es el proceso a través del cual una cadena de DNA (**DNA - DeoxyriboNucleic Acid**) es enzimáticamente copiada por una **RNA polimerasa DNA-dependiente (RNAPol)** para producir una cadena de RNA (**RNA - RiboNucleic Acid**) complementario, a partir del cual se lleva a cabo la expresión de los genes<sup>3</sup> y la síntesis de proteínas (14) [ver Figura I2B]. La regulación de la transcripción en las bacterias sucede principalmente antes y durante el inicio de este proceso: modificando la holoenzima RNA polimerasa, haciendo re-arreglos estructurales de la región reguladora o, por medio de pequeñas moléculas de RNA que también activan o inhiben la transcripción al unirse a sitios específicos. De forma general, la regulación transcripcional es llevada a cabo por la RNA polimerasa, ayudada por elementos intrínsecos (terminadores, promotores, operadores) e extrínsecos al DNA (factores  $\sigma$ , factores transcripcionales) que dirigen y coordinan su actividad durante las primeras etapas del proceso (15) [ver Figura I2-A y B].

El **promotor** es uno de los elementos intrínsecos del DNA más importante para la transcripción, pues indica dónde iniciar y, a través del factor  $\sigma$ , funciona como punto de anclaje para la RNAPol al DNA. El promotor está conformado por dos hexanucleótidos (uno localizado en la posición -10 “caja-10” y el otro en la posición -35 “caja-35”) separados por una región de entre 15 y 21 pares de bases (bp – base pairs) (14) [ver Figura I2-A y B]. La secuencia de los hexanucleótidos es distinta para cada factor  $\sigma$ . En algunos promotores, existe una estructura rica en AT (el **elemento UP**) que incrementa la actividad del promotor, se localiza a 20 bases río arriba de la región -35 y es reconocida por el dominio C-terminal de la subunidad  $\alpha$  de la RNAPol [ver Figura I2B]. Por otro lado, los **operadores**, o sitios de unión al DNA (**bsDNA – DNA binding site**), son secuencias específicas para los factores transcripcionales de aproximadamente 20 bps, localizados dentro de la región reguladora. Los operadores se pueden ubicar río arriba (*upstream*), traslapados con el promotor, o río abajo (*downstream*) del inicio del gen (15) [ver Figura I2B].

Los **factores sigma ( $\sigma$ )** corresponden a una de las subunidades de la holoenzima RNA polimerasa y tienen tres funciones principales: *a*) garantizar el reconocimiento de las secuencias promotoras específicas; *b*) posicionar la holoenzima sobre un promotor blanco; y *c*) facilitar el desenrollamiento del dúplex de DNA que está cercano al sitio de inicio de la transcripción. Muchas bacterias contienen múltiples factores  $\sigma$  que son capaces del reconocimiento de diferentes promotores en distintas condiciones ambientales (15).

Los **factores transcripcionales (TF – Transcription Factor)** son proteínas (monómero o multímero) que se unen a bsDNAs específicos (operadores) en ambas hebras del DNA sin abrirlo, formando una interacción por puentes de H, cuya función es activar o reprimir la transcripción de un **gen(es) blanco (TG – Target Gene)** [ver Figura I2B]. Los TFs llevan a cabo su actividad por la presencia o ausencia de sus señales, llamados **efectores o ligandos**, los cuales corresponden a distintos tipos de metabolitos o grupos químicos de óxido-reducción, que cambian la conformación o el estado químico de los TFs (16).

<sup>3</sup> Gen (14). Región de DNA que controla una característica hereditaria discreta, usualmente corresponde a un simple polipéptido o RNA estable. Esta definición incluye la unidad funcional entera, abarcando secuencias de DNA codificantes y secuencias regulatorias de DNA no codificantes.



**Figura I2. RNA polimerasa (RNAPol) y los componentes de la transcripción.** **A)** Un modelo basado sobre los estudios cristalográficos del anclaje inicial de la holoenzima RNAPol a un promotor (14). **B)** Esquema del modelo mostrado en la parte A) (14-15), ilustrando las diferentes interacciones entre los elementos de la transcripción. Para ambos esquemas, son mostrados en amarillo las secuencias **consenso** del **promotor** para los elementos **-35** (TTGACA) y **-10** (TATAAT), así como en rojo la secuencia extendido **-10** (TGn) y el **elemento UP**. La **RNAPol** está conformada por un núcleo enzimático de cuatro subunidades proteínicas (una  $\beta$ , una  $\beta'$  y dos  $\alpha$ ) y una subunidad de unión temporal (el factor  $\sigma$ ).  $\beta$  y  $\beta'$  juntas forman el centro catalítico (sitio activo  $Mg^{2+}$  en magenta),  $\beta'$  (en rosa) se une a la hebra templado,  $\beta$  (en azul) se encarga de la unión de los nucleótidos, las dos  $\alpha$  (en gris:  $\alpha$ NTD –dominio amino y  $\alpha$ CTD –dominio carboxilo) se requieren para interactuar con los **fatores transcripcionales** (TFs en púrpura) y reconocer al promotor; además, por medio del **factor  $\sigma$**  (sus diferentes dominios en rojo) ocurre el reconocimiento y unión al promotor.

Cuando RNAPol ( $\alpha\beta\beta'$ ) se unen al factor  $\sigma$ , se forma el complejo **holoenzima ( $\alpha\beta\beta'\text{-}\sigma$ )**, que sólo existe durante las dos primeras etapas de la transcripción. La RNAPol tiene afinidad general por el **DNA** (mostrado en verde), como holoenzima su afinidad hacia el promotor incrementa  $10^7$  veces. Para iniciar la transcripción, la holoenzima pasa por varios estados de unión al DNA: 1) **Complejo cerrado binario (RPc)**, cuando la holoenzima está unida al promotor; 2) **Complejo abierto (RPa)**, cuando se separan las dos cadenas de DNA, pero aún no se inicia la síntesis del **RNA mensajero (mRNA)** en verde ondulado; 3) **Complejo abierto de inicio (RPin)**, cuando la holoenzima está como RPa y tiene unidos cuatro nucleótidos trifosfatados. Durante el RPIn, la holoenzima se mantiene sintetizando mRNA, pero son fragmentos muy cortos que se abortan y vuelve a empezar hasta que puede continuar la síntesis con más nucleótidos, liberándose así del promotor y del factor  $\sigma$ , como RNAPol.

Los elementos intrínsecos en el DNA, promotor y **operadores (bsDNA en verde claro)**, se ubican río arriba (*upstream*) antes del inicio del gen (posición +1), en la **región “reguladora”** (cuyas posiciones se escriben con signo negativo). Ésta región coordina, con el promotor, donde se debe unir la RNAPol y, con los operadores, si se debe incrementar o disminuir la transcripción de los **genes (TGs en azul)** río debajo (*downstream*) de su inicio. Los elementos extrínsecos al DNA, el factor  $\sigma$  y los TFs, actúan sobre la región reguladora; de acuerdo al efecto que tengan sobre la transcripción se clasifican como: a) **positivos o activadores** si favorecen la unión de la RNAPol con su promotor o si eluden la barrera cinética para promover la estabilidad de RPc a RPa; b) **negativos o represores** si limitan el acceso de la RNAPol al promotor.

## II. Componentes y estructura de la TRN.

En 1961, François Jacob y Jacques Monod fueron los primeros en proponer la organización del DNA para su regulación conjunta. Propusieron que la transcripción de los genes es regulada por las interacciones específicas entre secuencias *cis* localizadas en la región reguladora y los productos de genes codificados en regiones *trans*. Las secuencias *cis* son los operadores y promotores, mientras que los productos de las *trans* son generalmente los TFs (14, 16). Así como también, desde los años 70's, los trabajos en diversas redes celulares (circuitos metabólicos, de regulación, inmunológicos, embriológicos, etc.) de Michael A. Savageau y Stuart A. Kauffman formalizaron las bases teóricas necesarias que ahora nos permiten entender diversas características de la estructura y organización de la regulación transcripcional (4-7).



De esta forma, se ha propuesto que la unidad básica de la **interacción de regulación genética** consiste de tres componentes: un **factor de transcripción (TF)**, su **sitio de unión a DNA (operador) (bsDNA)** y el **gen regulado o blanco (TG)** (17) [ver Figura I2B]. La colección total de tales interacciones regulatorias en un organismo puede ser conceptualizada como una red, referida como la **Red de Regulación Transcripcional (TRN – Transcriptional Regulatory Network)**. De esta forma, la TRN puede ser representada como un grafo<sup>4</sup> dirigido, en el cual los nodos representan los genes (TFs o TGs) y las aristas representan interacciones regulatorias dirigidas (18) [ver Figura I3].

Estructuralmente, la TRN es compleja porque los genes pueden estar regulados por más de un TF (ya que algunos genes se utilizan en más de una situación del ciclo de vida celular o en diferentes etapas de alguna condición ambiental); así como también, muchos TFs pueden controlar a más de un gen a través de uno o varios bsDNAs (17, 19-20) [ver Figura I3].

Derivado de ello, podemos delimitar varios niveles de organización en las TRNs. Al arreglo de la región reguladora y el(s) gen(es) correspondientes se le llama **unidad transcripcional (TU – Transcription Unit)** (14, 16). En las bacterias, los genes involucrados en una misma ruta metabólica o para un mismo proceso celular generalmente están acomodados de forma consecutiva, con una sola región reguladora formando una TU llamada **operón**, que se transcribe en un solo RNA mensajero (**mRNA – messenger RNA**) (14-15) [ver Figura I3]. A su vez, los operones se organizan como **regulones<sup>5</sup>** en un nivel mayor. Los regulones no son propiamente arreglos estructurales en el DNA, más bien, son operones (en distintas regiones del DNA) que se regulan conjuntamente por un solo TF en respuesta a una señal generalizada (14-16) [ver Figura I3].

<sup>4</sup> **Grafo** (18). Es un par de conjuntos  $G = \{P, E\}$ , donde  $P$  es un conjunto de  $N$  nodos (o vértices o puntos)  $P_1, P_2, \dots, P_N$  y  $E$  es un conjunto de aristas (o uniones o líneas) que conectan dos elementos de  $P$ .

<sup>5</sup> **Regulón** (14-16). La definición inicial delimita a un grupo de genes sujetos a regulación de uno y sólo un regulador (Maas W.K., 1964). Actualmente, a esta definición se ha denominado regulón simple, cuya diferencia con un regulón complejo radica en el número de factores de transcripción que regulan a un grupo de genes, y en un regulón complejo estricto es adicional mantener el efecto de cada regulador (activador o represor) sobre todos los genes regulados. **Nota:** en este estudio se usó la definición de regulón simple.



**Figura 13. Unidad básica de la interacción regulatoria genética.** Sobre el recuadro superior se esquematizan las interacciones de la proteína TrpR (que regula la transcripción del triptófano) en sus tres componentes: 1) un TF (TrpR como un óvalo de color púrpura), 2) su sitio de unión (rectángulos de color rojo – por represión - punteados) al DNA (las líneas grises) y, 3) el TG(s) (rectángulos flechados con dirección *forward* o *reverse*, según la cadena de DNA donde se localicen). El regulón de TrpR está formado por 5 operones, cada uno de los cuales, está conformado con al menos un sitio de unión al DNA para este TF y un TG al que regule. La flecha delgada negra indica el sitio de inicio de la transcripción (+1). Los rectángulos de color rojo (por represión) y verdes (por activación) rayados diagonalmente representan los sitios de unión al DNA para el TF TyrR (que regula la transcripción de tirosina) que también regula a algunos de estos operones. En el recuadro inferior se representa el grafo de las interacciones del regulón de TrpR (12 interacciones en total, una de las cuales es autorregulación), donde los nodos representan el TF (óvalo de color púrpura) y los TGs que regula (cuadros de color azul), unidos por medio de aristas dirigidas (flechas) que representan la dirección y el tipo de regulación (rojo: represora) de la interacción regulatoria.

Los distintos niveles de complejidad en las TRNs han sido evaluados con ciertas características estadísticas, las cuales han revelado que la estructura jerárquica de las TRNs se aproxima a una topología *libre de escala*<sup>6</sup>, donde la conectividad<sup>7</sup> de los nodos sigue una distribución del tipo *ley de potencias*<sup>8</sup> (7). Esto implica, para los nodos con conectividad de salida<sup>7</sup> (TFs), que pocos TFs tienen un gran número de interacciones (conexiones con TGs), de esta manera, dominan el comportamiento general de la red; mientras que la mayoría de los TFs presentan una conectividad baja con TGs. Así, el grupo de TFs con una alta conectividad (de salida) podrían tomar el papel de *hubs*<sup>9</sup> de regulación en la red. Estos *hubs* pueden ser caracterizados en las TRNs como **reguladores globales (GR - Global Regulators)**. Aunque una categoría de GR no sólo se atribuye a la conectividad que pueda tener un TF, sino también por el número y tipo de co-reguladores que presenta, los diferentes tipos de factores σ con los que interactúa, el número de otros TFs que regula, así como la variedad de condiciones experimentales donde ejerce su control (19). Por estas razones, algunos grupos de trabajo han diferido en el número y tipo de GRs propuestos para las TRNs que se han caracterizado previamente, aún cuando la conectividad de un TF pueda ser una medida acertada sobre su condición global o no en la regulación celular.

Sin embargo, es importante reconocer que a pesar de que están disponibles abundantes datos de secuencia y genomas completos, la determinación y recopilación experimental de las TRNs ha sido limitada a pocos organismos. Aún cuando trabajos previos de genómica estructural<sup>10</sup> han generado predicciones de interacciones del tipo proteína-DNA (24-26), no se ha determinado una relación clara entre la presencia de un TF, su TG y el bsDNA(s), que permita la transferencia de estas interacciones entre los genomas. Entonces, resulta difícil encontrar una medida específica entre la homología a nivel de secuencia, la función y la transferencia de la interacción<sup>11</sup> para cualquiera dos proteínas involucradas en una interacción de regulación transcripcional (27-29). Sin embargo, varios grupos han examinado recientemente la transferencia de las interacciones regulatorias de un organismo a otro usando enfoques de genómica comparativa (27, 29). La transferencia de tales interacciones involucra la asignación de funciones a TFs y TGs, basados sobre la similitud de la secuencia de las proteínas y sobre la conservación de patrones topológicos de la TRN, tales como motivos y módulos de interacciones (28, 30).

<sup>6</sup> **Topología libre de escala** (22). (*Scale free*) Es un término introducido por Barabási y Albert en 1999 que describe, a nivel genérico, cualquier grafo o red en la cual las conectividades de los vértices siguen una distribución que se aproxima a una ley de potencias (*power law*).

<sup>7</sup> **Conectividad (K)** (18). Las redes son caracterizadas por dos distribuciones de grado: la distribución de conectividad de salida,  $P_{out}(k)$ , significa la probabilidad que un nodo tiene  $k$  aristas de salida; y la distribución de conectividad de entrada,  $P_{in}(k)$ , es la probabilidad que  $k$  aristas apunten a un cierto nodo. Varios estudios (Albert y Barabási, 2002) han establecido que tanto  $P_{out}(k)$  y  $P_{in}(k)$  tienen distribuciones *power law*.

<sup>8</sup> **Distribución de tipo ley de potencias** (18). (*Power-law*) Matemáticamente, una secuencia finita  $y = (y_1, y_2, \dots, y_n)$  de números reales, asumidos sin pérdida de generalidad que son ordenados tal que  $y_1 \geq y_2 \geq \dots \geq y_n$ , se dice que sigue una ley de potencias o relación no estocástica de escala si  $k = cy_k^{-\alpha}$ , donde  $c$  es (por definición) el intervalo de  $y_k$ ,  $c$  es una constante fija y  $\alpha$  es llamado el índice de escala. De esta forma, el que una red tenga una distribución *power law*, significa que la frecuencia de nodos ( $N$ ) como una función de su conectividad  $k$  decrece como  $k^{-\alpha}$ , indicando una alta variabilidad en el número de conexiones, con un número pequeño de nodos altamente conectados y con un alto número de nodos poco conectados.


<sup>9</sup> **Hubs** (22). Definido normalmente como un nodo con un alto número de conexiones en una red determinada.

<sup>10</sup> **Genómica estructural** (23). Es la rama de la genómica orientada a la caracterización y localización de las macromoléculas derivadas de los genomas, en base a la cristalografía de rayos X, el análisis de espectroscopía de resonancia magnética nuclear –NMR, entre otros. La información originada nos permite entender las características de las macromoléculas y los mecanismos biológicos de su función a nivel atómico y molecular.

<sup>11</sup> **Transferencia de la interacción** (16). Anotación de una interacción, del tipo proteína-proteína o proteína-DNA, desde un organismo modelo a otro usando genómica comparativa.

### III. El método Regulog para la transferencia de las interacciones regulatorias.

El enfoque **Regulog**<sup>12</sup> usa datos conocidos experimentalmente para predecir interacciones proteína-DNA en otros genomas. Se predice que una interacción (TF y su TG) en una especie ocurre en otra especie si su mejor apareamiento de secuencia ha sido determinado en un grupo blanco de genomas. La presencia de uno de los componentes de la interacción regulatoria no es suficiente para transferir la anotación de la interacción, sino que es necesario que ambos, el TF y su TG, sean detectados en el organismo de interés [ver Figura I4]. Usando este enfoque, Yu *et al.* (27) han mostrado que los genes ortólogos<sup>13</sup> de TFs y TGs de *Saccharomyces cerevisiae* y de *Drosophila melanogaster* comparten la misma interacción regulatoria si los TFs de estos eucariontes tienen una identidad a nivel de secuencia de proteína mínima del 30 al 60%, dependiendo de la familia de proteínas.



**Figura I4. Representación esquemática del enfoque REGULOG.** En el organismo de referencia, un TF A se une a su sitio de unión ( $S_A$ ) y regula al gen B río abajo. Para llevar a cabo el mapeo de regulogs, 1) TF A' en el organismo de interés (blanco) necesita ser el ortólogo de A. 2) Las proteínas B y B' serían también ortólogos. 3) La secuencia de DNA río arriba del gene B' necesita contener el mismo motivo ( $S_{A'}$ ) como  $S_A$ . La interacción entre TF A' y  $S_{A'}$  es el interolog proteína-DNA de A y  $S_A$ . La relación regulatoria entre A → B y A' → B' son regulogs. Sin embargo, la condición 3) no es necesaria que se cumpla, ya que solamente TF A y A' necesitan compartir ≥ 30% de identidad.

<sup>12</sup> Regulog (27). (Protein-DNA interolog) Walhout *et al.* (2000) introdujeron el concepto de “interologs” que se definen como pares de ortólogos de proteínas interactuando en diferentes organismos. Yu *et al.* (2004) generalizaron este concepto para interacciones del tipo proteína-DNA, en donde se mostró que todos los TFs dentro de un cierto intervalo de identidades invariables ( $\geq$  de 30 y 60% de identidad dependiendo de la familia) comparten la misma secuencia de unión al DNA y, por lo tanto, se mostró que en general existe la misma relación regulatoria de la transcripción.

<sup>13</sup> Ortólogos (31). Son definidos como proteínas en diferentes especies que evolucionaron de un ancestro común por especiación y usualmente tienen la misma función. Ver material y métodos.

De esta forma, un ***regulog*** se define como el par de ortólogos que refleja una relación de regulación conservada entre proteínas interactuando a través de diferentes especies (16). En otras palabras, cuando una interacción proteína-DNA es transferida a través de las especies, la relación regulatoria entre el TF y su TG es también implícitamente transferida.

Yu *et al.* (2004) sugieren tres condiciones que son necesarias para transferir *regulogs*:





1. El TF A y su homólogo A' deben compartir al menos  $\geq 30\%$  de identidad de secuencia<sup>14</sup>.
2. El TG B y su homólogo B' deben ser ortólogos.
3. La secuencia de DNA río arriba (*upstream*) de B' debe contener el mismo bsDNA que la de B.

Sin embargo, es necesario hacer notar que la tercera condición no es estrictamente necesaria para llevar a cabo la transferencia de *regulogs*. De esta forma, Yu *et al.* (2004) mostraron que el TF A y A' solamente necesitan compartir  $\geq 30\%$  de identidad. Entonces, el enfoque *Regulog* requiere mínimamente de la primera y segunda condición. Además, el uso de la información basada en los bsDNAs podría generar los siguientes problemas metodológicos:

- a) La reducción drástica en el tamaño de las TRNs de referencia, ya que sólo pocos TFs en la red tienen caracterizados experimentalmente los bsDNAs para construir un perfil confiable de búsqueda de secuencias consenso en otros genomas.
- b) La reducción del número de genomas que pueden ser comparados, ya que no es posible la detección confiable de los bsDNAs en organismos distamente relacionados, lo cual generaría un sesgo sobre un análisis a gran escala.
- c) Una menor cobertura en las predicciones, dado que los bsDNAs para un mismo TF están poco conservados, incluso en organismos cercanamente relacionados. A la fecha, no existe una tendencia clara entre la conservación de los TFs y la de sus bsDNAs. Dentro de los ejemplos más conocidos y contrastantes se encuentran los regulones de los TFs BirA (21) y LexA (13), donde el elemento regulador (TF) y regulado (TG) se han conservado en bacterias; así como su interacción de regulación transcripcional, pero no necesariamente por medio de los mismos bsDNA [ver Tabla I1].

---

<sup>14</sup> Formalmente, A y A' deberían ser ortólogos. Sin embargo, operacionalmente esta condición fué definida en el trabajo de Yu *et al.* (2004) por el criterio de porcentaje de identidad en las secuencias, a partir del cual se incluyeron secuencias parálogas en el análisis y con ello, una mayor cobertura en las predicciones. Sin embargo, no puede inferirse un mayor intervalo de confianza sobre las funciones de los TFs predichos. Ya que el hecho de que existan familias de TFs que presentan diferentes relaciones con el porcentaje de identidad en las secuencias refleja su diversidad regulatoria. De esta forma, familias con altos porcentajes de identidad contienen TFs que regulan muchos procesos diferentes; mientras que aquellas con bajos porcentajes de identidad contienen TFs que regulan pocos procesos diferentes (Luscombe y Thornton, 2002). En este sentido, los TFs parálogos incluidos en las predicciones de Yu *et al.* (2004) no garantizan la conservación de sus roles funcionales con respecto al TF del organismo de referencia.

BirA [16131807   b3973]	Características	LexA [16131869   b4043]
EC: 6.3.4.15 Ligasa para la proteína biotina. Represor transcripcional del operón de biotina	FUNCIÓN	EC: 3.4.21.88 Represor transcripcional de genes involucrados en la respuesta de daño a DNA (SOS)
	REGULÓN	
	DOMINIOS y bsDNA(s)	
<ul style="list-style-type: none"> <li>Dímero (PDB: 2EWN, PFAM v10, 3D-Rasmol v2.6).</li> <li>PF08279: N – terminal bsDNA (Helix-turn-helix).</li> <li>PF03099: Central catalítico, contiene el sitio de unión para el biotinyl-5' -AMP (también requerido para regulación).</li> <li>PF02237: C – terminal con función desconocida.</li> </ul>		<ul style="list-style-type: none"> <li>Dímero (PDB: 1JHH, PFAM v10, 3D-Rasmol v2.6).</li> <li>PF01726: N – terminal bsDNA (Helix-turn-helix).</li> <li>PF00717: Central y C – terminal, auto-proteolítico (hidrólisis de unión Ala - Gly) al interactuar con RecA (Peptidasa S24).</li> </ul>
TTGTAAACC - (16) - GGTTTACAA	<i>Escherichia coli</i>	CTGTN - (8) - ACAG
tTGtaAACc-N(14)...(16)-GGTTtACAAa	Proteobacteria	CTGTN - (8) - ACAG (gamma γ - beta β) GAACN - (7) - GAAC ó GTTCN - (7) - GTTC (alfa α)
wwTGTTAAC-N(14)...(16)-GGTTtACAAw (Eubacteria - Arquea)	No Proteobacteria	CGAACrNryGTTyC (Firmicutes, gram +) rGTACNNNdGTwCb (Cyanobacteria)

**Tabla II. Comparación de las características regulatorias de dos regulones transcripcionales.** Sobre la columna izquierda, **BirA** constituye un excelente modelo para la transferencia de interacciones pues tanto este TF, los TGs a los que regula y su bsDNA se encuentran conservados en procariotes. De forma contraria, en el caso de **LexA** (en la columna derecha) sólo conservan en procariotes este TF y los TGs a los que regula. BirA presenta dos funciones, por un lado es una ligasa para la proteína biotina y por el otro es el represor transcripcional (flechas en color rojo) del operón de biotina, mientras que LexA tiene la función de regular a los genes involucrados en la respuesta SOS de daño a DNA (KEGG, <http://www.genome.jp/kegg/>). Sus componentes regulados constan de 5 TGs para el caso de BirA, mientras que LexA regula a 28 TGs (Regulon DataBase, <http://regulondb.ccg.unam.mx/index.html>). Las estructuras terciarias presentan tres dominios PFAM conservados para BirA y dos para LexA, de los cuales, el que corresponde al número uno en ambos casos es el dominio de unión al DNA (Helix-turn-helix) (PFAM, <http://www.sanger.ac.uk/Software/Pfam/>). Se puede apreciar que los bsDNA para BirA, caracterizados computacional y experimentalmente, presentan una secuencia consenso conservada en eubacterias y arqueas (32); mientras que para LexA han sido reportado al menos 5 diferentes bsDNA en diversas clases y *phyla* bacterianos (33).

Más recientemente, Sharan *et al.* (34) asociaron funciones a las proteínas usando la conservación de grupos de interacciones en las redes proteína-proteína en genomas eucariontes. Ésto implica que una alta similitud de secuencia<sup>15</sup> no necesariamente significa que la función está conservada o que pueda ser compartida por otra secuencia de menor similitud; sino que la conservación de las interacciones al nivel de motivos o módulos en las redes, permite una mayor cobertura en la determinación de la función de una

<sup>15</sup> Hits. Generalmente, se toma el primer bit de una corrida de BLAST (el de mayor significancia estadística según el e-value calculado).

proteína (nodo) a partir de su contexto. De esta forma, los mejores apareamientos de secuencia (*hits*)<sup>15</sup> no siempre están presentes dentro de los grupos de proteínas conservadas. Esto proporciona una ventaja en la extensión de las predicciones porque se incrementa la tasa de detección de funciones conservadas al incluir familias de parálogos y la pérdida de genes. La alta especificidad de las predicciones realizadas por Sharan *et al.* (34), pueden ser apoyadas porque la conservación es evaluada en el contexto de una “subred” de interacción de proteínas y no independientemente para cada interacción. Sin embargo, se ha demostrado que los patrones de conservación entre interacciones proteína-proteína *versus* interacciones proteína-DNA es diferente (27), y que la lógica regulatoria transcripcional difiere radicalmente entre eucariontes y procariotes (35). Como una consecuencia, la realización de métodos de mapeo de las interacciones transcripcionales bajo la estrategia de Sharan *et al.* (34) puede ser evaluada a una gran escala, pero con bajos niveles de confianza sobre las predicciones (20, 27).

De esta forma, por medio del enfoque *Regulog* es posible reconstruir la evolución de las TRNs a través del mapeo de los componentes y de las interacciones regulatorias a lo largo del amplio número de genomas completamente secuenciados. El entendimiento sobre la evolución de las TRNs no sólo mejoraría nuestro conocimiento acerca de las restricciones biológicas de la regulación transcripcional que los diferentes organismos han adquirido para la adaptación a su ambiente, sino que también nos permitiría descifrar los principios del diseño básico sobre los que subyace su fenotipo molecular (36). A partir de los cuales, podemos reconstruir una historia regulatoria a partir del grupo de interacciones que han sido conservadas para diversos procesos celulares en las bacterias.

#### **IV. Comparación general de los modelos: *Escherichia coli* vs *Bacillus subtilis*.**

En este trabajo usamos las TRNs de dos diferentes modelos de bacterias. Uno de estos es la TRN de la bacteria gram-negativa *Escherichia coli* K12 contenida en **RegulonDB (Regulon DataBase)**, la cual es la mejor conocida en bacterias (21). Esta base de datos contiene la información experimental correspondiente a aproximadamente 20% de la TRN de *E. coli* (19). El segundo procarionte mejor estudiado en términos de su regulación transcripcional es la bacteria gram-positiva *Bacillus subtilis*. Obtuvimos el grupo completo de las interacciones regulatorias de esta bacteria documentada en **DBTBS (DataBase of Transcriptional regulation in Bacillus Subtilis)** (37). La Tabla I2 muestra una comparación entre estos dos organismos sobre sus principales características, así como de los elementos que conforman a sus TRNs.

Aún cuando ambas bacterias son de vida libre y requieren concentraciones similares de niveles de oxígeno y de temperatura. *E. coli* se ha adaptado a vivir dentro de su hospedero, mientras que *B. subtilis* se ha adaptado a ambientes de suelo (38-39) [ver Tabla I2-I]. Con respecto a sus características morfológicas, aunque ambos organismos presentan una forma cilíndrica; por un lado, *E. coli* presenta movilidad por medio de flagelos peritíricos (que rodean su cuerpo), mientras que *B. subtilis* no posee flagelos y tampoco presenta movilidad (38-39) [ver Tabla I2-II].


Otra importante diferencia entre ambos modelos es que *B. subtilis* presenta dos distintos procesos de división celular, el de división binaria o vegetativo es compartido con *E. coli* y con todas las bacterias. Sin embargo, en estado de inanición o condiciones físico-químicas adversas en el ambiente, *B. subtilis* lleva a cabo un proceso de diferenciación celular que dará paso a la formación de esporas y de un cuerpo frutal de forma colectiva (39). La esporulación se lleva a cabo en siete estadios de diferenciación que empieza con una división celular asimétrica que produce dos tipos celulares distintos: la célula pre-espora (más pequeña) y la célula madre. Ambas células contienen el mismo material genético, pero utilizan diferentes interacciones en la expresión de los genes (40-41). De esta forma, en la célula pre-espora se sintetizará la endospora, madurará y liberará como una espora latente. La mayoría de la esporulación se lleva a cabo al nivel de la regulación transcripcional (41) y es controlada por diversos factores σ (40) [ver Tabla I2-III].

Las diferencias detectadas en la morfología, los estadios de vida, así como en los nichos ecológicos entre *E. coli* y *B. subtilis* hace que ambos organismos respondan a diferentes necesidades y requerimientos metabólicos, de energía, proliferación y de división celular, lo cual puede verse reflejado en los componentes que regulan la expresión primaria de los genes. En conjunto, el componente regulador (TFs) y el regulado (TGs) de la TRN comprenden una proporción significativa del genoma en cada organismo (23% en *Escherichia coli* y 19% en *Bacillus subtilis*) (21), lo cual constituye un componente genético considerable para la diversificación de los fenotipos bacterianos. Entender cómo evoluciona la TRN nos permite evaluar la expansión y el patrón de la diversidad genética en la regulación transcripcional, los efectos fenotípicos de la variación molecular y sus posibles consecuencias ecológicas.

Característica	<i>Escherichia coli</i> K12 <sup>a</sup>	<i>Bacillus subtilis</i> <sup>b</sup>	Referencias
Linaje	Bacteria Proteobacteria Gammaproteobacteria Enterobacteriales Enterobacteriaceae <i>Escherichia</i>	Bacteria Firmicutes Bacillales Bacillaceae <i>Bacillus</i>	<sup>a</sup> y <sup>b</sup> KEGG ( <a href="http://www.genome.ad.jp/kegg/">http://www.genome.ad.jp/kegg/</a> )
Estilo de vida	Libre/Asociado hospedero	Suelos	<sup>a</sup> Blattner F.R., et al. (1997) <sup>b</sup> Kunst F., et al. (1997)
Patógeno	NO	NO	
Requerimiento de O <sub>2</sub>	Facultativo	Facultativo	<sup>a</sup> y <sup>b</sup> Bergey's Manual of Determinative Bacteriology ( <a href="http://www.cme.msu.edu/Bergeys/">http://www.cme.msu.edu/Bergeys/</a> )
Niveles de temperatura	Mesófilo	Mesófilo	
Tamaño de genoma (pb)	4 639 675	4 214 630	<sup>a</sup> Blattner F.R., et al. (1997) <sup>b</sup> Kunst F., et al. (1997)
# de CDS	4 289	4 106	
# de RNAs	156	119	
% de G – C	50	43	<sup>a</sup> y <sup>b</sup> NCBI ( <a href="http://www.ncbi.nlm.nih.gov/genomes/">http://www.ncbi.nlm.nih.gov/genomes/</a> )
# de interacciones	1678	785	
# de TFs	119	99	<sup>a</sup> RegulonDB ( <a href="http://regulondb.ccg.unam.mx">http://regulondb.ccg.unam.mx</a> )
# de TGs	850	666	<sup>b</sup> DBTBS ( <a href="http://dbtbs.hgc.jp/">http://dbtbs.hgc.jp/</a> )
# de regulones	118	93	
# de factores sigmas	7	17	
Reguladores globales	7 (CRP, FNE, IHF, FIS, ArcA, Hns, LRP)	8 (CcpA <sup>1</sup> , AbrB <sup>2</sup> , ComK <sup>3</sup> , FUR <sup>4</sup> , PhoP <sup>5</sup> , TnrA <sup>6</sup> , CodY <sup>7</sup> , PurR <sup>8</sup> )	<sup>a</sup> Martinez-Antonio & Collado-Vides (2003) <sup>b</sup>

### *Bacillus subtilis*

Tomadas y adaptadas de Kolter Lab  
(<http://gasp.med.harvard.edu/collaborations.html>)



### *Escherichia coli* K12

**Tabla I2. Comparación de las características más sobresalientes de los modelos a usar en este trabajo.** La bacteria gram-negativa *E. coli* y la gram-positiva *B. subtilis* presentan, entre otras características, estilos de vida y reguladores transcripcionales globales diferentes. <sup>b</sup> Referencias de los GRs de *B. subtilis* al final. En I, II y III se muestran las diversas diferencias morfológicas y de diferenciación celular entre ambos organismos.

## **OBJETIVO GENERAL**

La motivación del proyecto estriba en conocer las restricciones y principios mínimos que la regulación transcripcional ha experimentado a lo largo de la evolución del fenotipo en las especies bacterianas.

De esta forma, usaremos una versión modificada del enfoque Regulog para poder identificar los componentes de la interacción regulatoria, pares de interacciones y regulones de las redes de regulación transcripcional de *Escherichia coli* y *Bacillus subtilis* a través de la comparación contra genomas completos de especies pertenecientes a los dominios celulares de Bacteria, Archaea y Eukarya.

## **OBJETIVOS PARTICULARES**

- **Cuantificar la extensión (en 204 genomas secuenciados) de los componentes individuales, los pares de interacciones y grupos de interacciones (regulones) que conforman la red de regulación transcripcional desde dos modelos bacterianos.**
- **Inferir las relaciones existentes entre la segregación filogenética, el estilo de vida y la conservación de la red de regulación transcripcional en las especies bacterianas.**
- **Determinar si existe un grupo de interacciones regulatorias conservadas en las bacterias, y si éstas tienen asignadas funciones similares a las reportadas previamente en otros sistemas celulares.**
- **Tratar de entender cómo las redes de regulación transcripcional han evolucionado y, de qué forma estas redes influyen en el proceso de adaptación fenotípica de las bacterias.**

## **HIPÓTESIS**

Dado que se ha demostrado en trabajos previos que las redes de interacciones metabólicas y las de proteína-proteína se encuentran conservadas en una gran escala filogenética (desde procariotes hasta eucariotes), esperamos que a partir del concepto de ortología, las redes de regulación transcripcional (conformadas de interacciones proteína-DNA) se encuentren conservadas en correspondencia con la distancia filogenética de los organismos bacterianos (Bacteria y Archaea).

## MATERIALES Y MÉTODOS

**A) Colección de proteomas.** Un total de 204 genomas completamente secuenciados, incluyendo *Escherichia coli* K12 y *Bacillus subtilis* fueron obtenidos de la base de datos Kyoto Encyclopedia of Genes and Genomes (KEGG, <ftp://ftp.genome.ad.jp/pub/kegg/genomes/>) (42) [ver Esquema M1-I]. Ver **ANEXO 1** para detalles acerca de los 204 genomas completamente secuenciados que se usaron en este estudio.

**B) Datos de las interacciones proteína-DNA.** Obtuvimos las interacciones regulatorias de *E. coli* K12 de la base de datos RegulonDB version 4.0 (21), la cual recopila la información experimental extraída de la literatura. También obtuvimos las interacciones regulatorias de *B. subtilis* de la base de datos DBTBS (37). En este trabajo, sólo se consideraron aquellas interacciones regulatorias donde los TFs y los TGs codifican para un polipéptido. Así, las interacciones que involucran tRNAs y otros TGs que no codifican para un polipéptido fueron ignoradas. De igual forma, hay varios TFs que activan y reprimen al mismo TG a través de la presencia de más de un sitio de unión al DNA (e.g. CRP regula a *galE* como activador o represor a partir de dos diferentes sitios de unión a DNA); estos casos fueron considerados como interacciones redundantes y solamente una de las interacciones fue usada para representarlas en el grupo final. De esta forma, un total de 1678 interacciones regulatorias no redundantes que representan 119 TFs actuando sobre 850 TGs fueron incluidas en este trabajo para la TRN de *E. coli* [ver **ANEXO 2A**]. Mientras que un total de 785 interacciones no redundantes representando 99 TFs afectando 666 TGs fueron incluidos de la TRN de *B. subtilis* [ver **ANEXO 2B**].

**C) Detección de TFs y TGs potenciales en diversos genomas.** Ha sido extensamente reportado que: la duplicación de secuencias, la divergencia y la recombinación son las principales fuentes de variación funcional en la evolución de las proteínas (43-44). Sin embargo, es importante notar que dado que la definición de “función” ha sido vaga, diferentes enfoques han sido considerados en genómica comparativa para delimitarla (28, 45-46). En este trabajo, asignamos papeles funcionales a TFs y TGs en otros genomas usando la intersección de tres criterios para la detección de proteínas ortólogas: a) el mejor hit bidireccional (BDBHs - Bi-Directional Best Hits), b) la cobertura en el alineamiento BLASTP (47) y c) la conservación de dominios PFAM (48) [ver Esquema M1].

Los ortólogos son definidos como proteínas en diferentes especies que evolucionaron de un ancestro común por especiación (31) y usualmente mantienen la misma función. Las proteínas que recientemente evolucionaron de un ancestro común por duplicación previa a cualquier evento de especiación son llamados “outparalogs” y en mucho menor proporción mantienen la misma función (49). Por contraste, los “inparalogs” son aquellos que han evolucionado por duplicaciones genéticas después del evento de especiación y en mayor medida estas secuencias conservan también su función. Operacionalmente, ambas


secuencias *inparalogs* y ortólogos son usualmente definidas como los homólogos de mejor apareamiento o como el mejor hit bidireccional en otro organismo (50-52). Las secuencias en el mismo genoma con más de 95% de identidad, estimadas con el programa CD-HIT (53), fueron consideradas en este trabajo como “*inparalogs*” e incluidas en grupos de paralogía reciente, en los cuales un solo representante (el que asigna CD-HIT) fue considerado para la búsqueda de los ortólogos, y con ello evitar menor cobertura en los BDBHs [ver Esquema M1-II.1]. Para identificar ortólogos usamos la definición de BDBHs a través de genomas depurados al 95% de identidad, con un e-value de BLASTP significativo ( $\leq 10^{-3}$ ), usando el programa WU-BLAST (47). Sin embargo, la asignación funcional no está completa con sólo este enfoque.

Es bien conocido que los dominios de una proteína determinan su función específica y que éstos representan unidades evolutivas. Especialmente para proteínas con más de un dominio, donde el patrón de conservación funcional es más complejo. De esta forma, las proteínas tienden a compartir funciones si ellas contienen los mismos dominios en un arreglo similar (28, 54-55). Sin embargo, es importante considerar que un incremento en el número de dominios puede cambiar la función original de una proteína (56). Definimos los dominios conservados en las secuencias analizadas en este trabajo a través de la librería de Modelos basados en Cadenas de Harkov (HMM - *Hidden Markov Models*) tomados de la base de datos PFAM versión 10 (48), usando el programa HMMER 2.3.1 (57) con un e-value  $\leq 10^{-3}$  [ver Esquema M1-II.3]. En adición, al menos un 70% del modelo PFAM fué cubierto por la secuencia.

Operacionalmente, identificamos ortólogos como aquellas proteínas que satisfacen las siguientes cuatro condiciones:

1. Secuencias que en el genoma de interés tienen el mejor hit bidireccional con el genoma de referencia con un e-value BLASTP significativo ( $\leq 10^{-3}$ ).
2. Al menos el 70% de la secuencia de referencia debe estar incluida en el alineamiento BLASTP.
3. Secuencias candidatos que tengan uno o más dominios PFAM en la misma orientación y arreglo que aquellos de la secuencia de referencia y que no incrementen el tamaño total de las proteínas de referencia en más que 100 residuos.
4. Todas las secuencias que fueron incluidas previamente en los grupos de *inparalogs* fueron considerados candidatos que mantienen la función sólo si las condiciones 1, 2 y 3 son verdaderas para la secuencia representativa del grupo.

De esta forma, identificamos los ortólogos y los dominios PFAM de 119 TFs y 850 TGs de la TRN de *E. coli*, y de 99 TFs y 666 TGs de la TRN de *B. subtilis*, así como para el resto de las proteínas de los genomas completos de *E. coli* y *B. subtilis* en los genomas completos de 175 bacterias, de 19 arqueas y de 10 eucariontes. Una vez obtenidos los ortólogos, nos basamos en las interacciones de la TRN de la especie de referencia para construir matrices de presencia y ausencia de las interacciones por medio del método Regulog, donde la presencia de ambos componentes, el TF y su TG son necesarios para transferir la interacción a las especies de interés [ver Esquema M1-III y IV].



**Esquema M1. Representación gráfica de la metodología utilizada para transferir interacciones.** Se usó el método Regulog para transferir las interacciones regulatorias de la TRN de *E. coli* y *B. subtilis* a través de 175 genomas bacterianos, 19 arqueas y 10 eucariontes (**sección I**), para lo cual usamos la aproximación de tres enfoques genómicos en la detección de ortólogos (**sección II**): 1) el mejor hit bidireccional (BDBHs), la reducción de inparalogs se usó como estrategia para evitar una menor cobertura de los BDBHs detectados, ya que secuencias entre los organismos de referencia e interés que son parálogos recientes y pueden desviar la bidireccionalidad de la comparación; 2) 70% de la cobertura de la secuencia de referencia en el alineamiento BLASTP, y 3) la obtención de dominios conservados PFAM. A partir de las interacciones conocidas para las TRNs de *E. coli* y *B. subtilis* y de los ortólogos determinados a través de estos tres enfoques, se trazaron las interacciones conocidas en todos los genomas analizados (**sección III a, b y c**) y aplicando el principio de Regulog se transfirieron las interacciones para cuyos componentes (TF y su TG) se encontraron los ortólogos correspondientes (**sección III c**) en los organismos de interés. La transferencia de tales interacciones después se analizó bajo diversos enfoques: componentes, pares de interacciones, reguladores globales y regulones, por medio del uso de métricas tales como el CI, DX, entre otras descritas más abajo (**sección IV**).

**D) Tratamiento de los datos.** Para facilitar el despliegue de los resultados, mostramos 110 genomas en todas las figuras, obtenidos al filtrar las cepas y especies del mismo género bacteriano, dejando como representante aquella con el número máximo de genes entre un género dado de organismos. Las relaciones filogenéticas derivadas de la distancia evolutiva desde *E. coli* y *B. subtilis* a todos los organismos fue obtenida según el procedimiento de reconstrucción filogenética previamente reportado por Brown *et al.* (58). La distancia evolutiva entre cualesquiera dos especies está relacionada a la suma de las distancias entre cada organismo y su ancestro común más cercano.

**E) Conservación de ortólogos.** Para normalizar el alcance de la conservación de los componentes (TFs y TGs) de la red regulatoria en comparación al genoma total, nosotros ideamos una métrica simple llamada **Índice de Conservación (Conservation Index - CI)** definido como:

$$CI = (x / TC) / (y / GC)$$

Donde **x** es el número de ortólogos presentes en el genoma de interés del número total de componentes (**TC** = TFs o TGs) de la TRN bajo consideración, y **y** es el número total de ortólogos detectados en el genoma de interés de todos los genes que codifican proteínas (CoDing Sequences - CDS) en el genoma de referencia (**GC**), en el caso de *E. coli* involucra 4248 CDS y para *B. subtilis* 4079 CDS. De esta forma, el **CI** es una medida de conservación de los componentes de la TRN de un genoma ponderado respecto a la conservación de sus genes. Un **CI** cercano a **0** indicaría que los componentes de la red regulatoria están pobemente conservados en comparación a la conservación del genoma, mientras que un **CI** cercano a **1** sugeriría que ambos, el TF y el TG están conservados en el mismo alcance. Un **CI** por arriba de **1** nos sugiere que el componente regulatorio (TFs o TGs) desde el organismo de referencia se encuentra conservado en mayor medida que el resto de su contenido genético.


**F) Persistencia de los pares de ortólogos de TF-TG a través de los genomas.** Las enormes diferencias en el tamaño del genoma y el contenido de genes entre bacteria, arqueas y eucariontes, o entre organismos con diferentes estilos de vida (parásito, endosimbiótico o de vida libre) pueden introducir un sesgo cuando se calcula la frecuencia de distribución de las interacciones regulatorias conservadas entre organismos (a partir de sus ortólogos presentes). Para corregir este problema, consideramos un **factor de distancia (D)** para evaluar la presencia o ausencia conjunta de los TFs y sus TGs a través de los genomas:

$$D_X = A' / (A' + A \cap B) \quad y \quad D_Y = B' / (B' + A \cap B)$$

$$\text{Donde } A' = A - (A \cap B) \quad y \quad B' = B - (A \cap B)$$

Para el factor de transcripción **X-TF**, el cual regula al gene blanco **Y-TG**, **A** denota el grupo de todos los organismos dentro de los 110 genomas no redundantes en los cuales un ortólogo para X-TF es encontrado, y **B** denota el grupo de todos los organismos en los cuales un ortólogo para Y-TG es detectado. **A'** representa el subgrupo de organismos que tienen un ortólogo para X pero no para Y, y **B'** representa el subgrupo de organismos que tienen un ortólogo de Y pero no para X. **A $\cap$ B** representa el número de organismos en los cuales los ortólogos (A y B) son detectados. Como un ejemplo, consideremos el caso de un par interactuando, TF-X y TG-Y, donde la distancia **TF (D<sub>X</sub>)** es más grande que la distancia **TG (D<sub>Y</sub>)** porque el TF contiene un mayor número de ortólogos que su TG. Entonces, D<sub>X</sub> puede contener un mayor número de ortólogos que D<sub>Y</sub>, y derivado de ello, el número de ortólogos únicos en D<sub>Y</sub> (B') debería ser más pequeño. En el límite, si la D<sub>Y</sub> no tiene ortólogos únicos relativos a D<sub>X</sub>, entonces la distancia D<sub>Y</sub> sería cero. Un procedimiento similar ha sido usado por trabajos anteriores, pero enfocándose sobre el contenido de dominios en los genomas (59) [ver Esquema M2].

Las distancias de cada par de TF y TG para las TRNs completas generadas por el enfoque arriba mencionado fueron clasificadas en tres clases: **a)** un TF y TG co-ocurren y se asume que mantienen su relación regulatoria ( $D_{TF} = D_{TG}$ ), **b)** el TF ocurre más que el TG ( $D_{TF} > D_{TG}$ ) y **c)** el TG ocurre más que el TF ( $D_{TF} < D_{TG}$ ) basados sobre umbrales predefinidos descritos en la próxima sección.



**Esquema M2. Representación gráfica de las categorías evolutivas a partir de la co-ocurrencia en los componentes de la interacción (un par TF y su TG).** Se calculó una métrica distancia (**D**) con la que se espera conocer una tendencia de co-ocurrencia entre los 1620 pares TF-TG en *E. coli* y 738 pares TF-TG pares en *B. subtilis* a través de los genomas analizados. Aquí mostramos el cálculo de D y la asignación a una de las tres categorías de co-ocurrencia para tres ejemplos de pares de interacción TF-TG obtenidas de la red de *E. coli*: DnaA-dnaN, Fur-entD y MetJ-ahpC. Se representa la distribución filogenéticas de los ortólogos del **TF (A en rojo)**, de su **TG (B en morado)**, y la ausencia de ortólogos (con blanco).

**G) Obtención de los valores de corte (*thresholds*) para identificar las categorías de los pares de interacciones TF-TG co-ocurriendo.** En ausencia de un grupo de control de interacciones regulatorias que puedan ser usadas para obtener los valores de corte (*thresholds*) para clasificar los pares TF-TG en las tres categorías y a partir de la métrica de distancia D, usamos la colección de pares de genes de las rutas metabólicas bajo la consideración de que estos últimos se encuentran más cercanos a co-ocurrir [ver ANEXO 3A]. Se ha observado que las rutas metabólicas se encuentran bien conservadas a través de los diversos grupos filogenéticos y son relativamente estables, en contraste de la maquinaria transcripcional (60-61).

Con la finalidad de representar mejor un valor de corte (*threshold*) para obtener pares de co-ocurrencias, el proceso de la obtención de distancias fue repetido para ambos genomas usando los pares de genes (que codifican para enzimas) de las rutas metabólicas documentadas en la base de datos KEGG (42) [ver ANEXO 3B]. Removimos la redundancia en los pares, ya que dos rutas diferentes pueden tener los mismos pares de genes. En resumen, para cada ruta metabólica P con N genes en ambos genomas, calculamos las distancias **D1** y **D2** de los pares de interacciones no-redundantes (**P1 - P2**) posibles ( $N^* (N - 1) / 2$ ). Un promedio de las distancias D1 y D2 fue calculado para la colección completa no-redundante de pares en cada ruta del genoma de referencia. Sin embargo, esta distancia promedio D1 o D2 es un sobre-estimado del alcance de la conservación para las interacciones regulatorias. De esta forma, una medida de **desviación estándar promedio** fue aplicada para generar pares interactuantes co-ocurriendo significativamente. Ya que las interacciones metabólicas D1 y D2 son sinónimos poco similares a  $D_{TF}$  y  $D_{TG}$  en las interacciones regulatorias, nosotros usamos un valor de corte final (*final threshold*) de:

$$T = \{(\langle D1 \rangle - STD1) + (\langle D2 \rangle - STD2)\} / 2$$

Donde **<D1>** y **<D2>** son los valores promedio de D1 y D2 para todos los pares, y donde **STD1** y **STD2** son las desviaciones estándares de D1 y D2 [ver ANEXO 3B].

**H) El análisis estadístico para la persistencia de las interacciones.** Para evaluar la significancia estadística de la co-ocurrencia de las interacciones regulatorias en estas tres diferentes clases, comparamos contra 1 000 redes regulatorias construidas aleatoriamente para *E. coli* y *B. subtilis*. Cada red aleatoria se reconstruyó con el mismo número de interacciones como las TRNs originales, pero con una reconexión de las aristas, manteniendo así el grado de conectividad de cada nodo como en la TRN original. Es importante notar que este método de aleatorización preserva el grado de conectividad de entrada y de salida del nodo y, de esta forma, se preserva la topología de las TRNs de referencia [ver ANEXO 4A]. Para este propósito, se utilizó el software mfinder (62) generando 1 000 redes aleatorias (-r) en el modo *default* que preserva la distribución de conectividad de cada nodo (*in-degree* y *out-degree*). En el análisis completo, excluimos las interacciones donde TFs son auto-regulados (*mutual-degree*), ya que estas

interacciones podrían generar un sesgo al calcular el efecto entre la co-ocurrencia de pares TF-TG. Así, el grupo final de interacciones analizadas bajo este enfoque incluyó 1620 pares TF-TG en *E. coli* y 738 pares TF-TG en *B. subtilis*. Una vez obtenidas las 1 000 redes aleatorias se calcularon nuevamente las métricas de distancias ( $D_{TF}$  y  $D_{TG}$ ) para cada red aleatoria. Para los datos generados en esta última fase, se calcularon dos medidas de significancia estadística, el Z-score y el p-value, dado que previamente se evaluó que los datos presentan una distribución normal [ver **ANEXO 4B**].

**I) Regulones conservados.** Para cada TF en *E. coli* y *B. subtilis*, calculamos el porcentaje de interacciones totales conservadas para cada regulón entre los genomas de interés. Para representar esta distribución, agrupamos estos porcentajes por la extensión de la TRN y la conservación del regulón a través del método *Centroid Linkage Clustering* con una métrica de distancia *Uncentered Correlation* del programa Cluster (63). Los datos agrupados representan 118 regulones en *E. coli* y 93 regulones en *B. subtilis* distribuidos a través de los genomas.

Calculamos grupos de regulones y de genomas por medio del método k-means del programa Cluster (63) para evaluar otras métricas de distancia, tales como *Euclidean* y *Kendall's Tau*, pero no se encontró que fueran significativamente diferentes en su habilidad para formar agrupamientos que delimiten los linajes de los genomas, así como tampoco de los regulones. Iniciamos la comparación con una colección de objetos (regulones y especies: 118 regulones en *E. coli*, 93 regulones en *B. subtilis*, y 110 genomas en ambos casos) que formaron 10 grupos (*clusters*) (k1) de regulones, y 5 grupos (*clusters*) (k2) de especies que fueron calculados a partir de la aleatorización de tales grupos en 100 veces.

La suma de las distancias dentro de los clusters es usada para comparar las diferentes soluciones de los agrupamientos. La solución del agrupamiento, en conjunto con la suma más pequeña de la distancia al interior al cluster, fué reclutada para cada métrica de distancia. De esta forma, comparamos los objetos (5 clusters de regulones y 10 clusters de las especies) para cada grupo generado con la métrica de distancia *Uncentered Correlation*, con respecto a los objetos agrupados en cada cluster generado con las métricas de distancias *Euclidean* y *Kendall's Tau*.

Finalmente, calculamos la proporción de objetos (regulones y especies) compartidos para cada cluster en las dos últimas métricas con respecto a *Uncentered Correlation*. En particular, encontramos que los resultados no son sensitivos a este parámetro. Así, decidimos usar la métrica de distancia *Uncentered*, la cual es ampliamente usada para representar la distribución de amplios grupos de datos biológicos [ver análisis en la página web diseñada para este trabajo, dirección más abajo].

**J) Interacciones regulatorias ancestrales.** Usamos la distribución filogenética de los pares TF-TG, el principio de Parsimonia y el método DOLLOP (64) para detectar si existe un grupo de interacciones regulatorias transcripcionales compartidos entre bacterias. Es importante hacer notar, que este método para detectar las interacciones conservadas es diferente de los otros enfoques descritos previamente en este trabajo. En este método no sólo se determina el número total de genomas en los que ocurre una interacción,

sino que se evalúa la presencia o ausencia de una interacción para cada grupo filogenético definidos previamente en Brown *et al.* (58).

En la primera fase, sólo consideramos la distribución filogenética de los genomas no-redundantes (como se describe en MÉTODOS-D de tratamiento de los datos). Además, no consideramos aquellos genomas menores a 1000 CDS y a aquellos organismos cuyos estilos de vida son considerados parásitos o endosimbiontes, ya que presentan una presión selectiva para reducir sus genomas. En el próximo paso, los pares de interacciones TF-TG fueron analizados en los grupos filogenéticos para cada dominio celular a través del principio de Parsimonia, el cual detecta caracteres que posiblemente se han transferido horizontalmente y los elimina de futuros análisis. Todas aquellas interacciones que fueron detectadas en más de la mitad del número total de especies en cada clado, fueron consideradas como las interacciones ancestrales para este grupo. En un último paso, los grupos de pares TF-TG candidatos como ancestrales fueron evaluados con el programa DOLLOP disponible en PHYLIP (64), en cuya base teórica se asume que en la evolución es mucho más difícil ganar una característica compleja que perderla [ver **ANEXO 5**].

**K) El material suplementario disponible *online*.** El material suplementario que incluye: **a)** los datos de las interacciones regulatorias (regulones) utilizadas para *E. coli* K12 y *B. subtilis*, **b)** el análisis estadístico realizado, **c)** la evaluación de la métricas de clustering utilizadas, **d)** las tablas de funciones de los TFs para ambos organismos, **e)** las figuras de alta resolución, así como **f)** las predicciones generadas en el presente trabajo en los 204 genomas completos pueden ser consultadas y se encuentran disponibles en la siguiente página web: [http://www.ccg.unam.mx/Computational\\_Genomics/TRNS/conservation/](http://www.ccg.unam.mx/Computational_Genomics/TRNS/conservation/)

## RESULTADOS Y DISCUSIÓN

### 1. Conservación de los componentes de las TRNs (TFs y TGs) entre las especies.


Basados en la información experimental de 119 TFs y 850 TGs de *Escherichia coli* K12 y 99 TFs y 666 TGs de *Bacillus subtilis*, identificamos sus contrapartes en 175 genomas de bacterias, 19 genomas de arqueas y en 10 genomas de eucariontes [ver ANEXO 6A y 6B]. La Figura R1A-B muestra la distribución de los ortólogos de los componentes (TFs y TGs) de la TRN de *E. coli* y *B. subtilis* a través de 110 genomas no redundantes, representando 23 diferentes *phyla* de los tres dominios celulares basados en la reconstrucción filogenética de Brown *et al.* (58) [ver MÉTODOS-D].

Desde la perspectiva de *E. coli* [ver Figura R1A], el *phylum* más cercano incluye 76 diferentes Proteobacterias agrupadas en cinco subdivisiones (15 α, 10 β, 42 γ, 4 δ and 5 ε). El alcance de conservación en estos grupos es el más alto de todos los *phyla* analizados, donde el 30% de los TFs y TGs están conservados<sup>16</sup>, con la excepción de organismos parásitos y endosimbiontes, los cuales comparten sólo 10% de los TFs y 20% de los TGs de la TRN de *E. coli*. En los Firmicutes, divididos en cuatro clases (10 Mollicutes, 22 Bacillales, 15 Lactobacillales y 4 Clostridia), se encontró que tienen del 20 al 30% de TGs y del 10 al 20% de TFs conservados; con la excepción de los organismos parásitos y endosimbiontes que pertenecen a los grupos de Mollicutes, Mycobacterium, Tropheryma, los cuales presentan menos del 5% de conservación para ambos componentes. Las fracciones de ortólogos en Firmicutes son similares a las detectadas en Actinobacteria. Otros *phyla* como Bacteroidetes, Fusobacteria, Planctomyces, Cyanobacteria, Deinococci, Aquifae y Thermotogae comparten del 10 al 25% de TGs y del 5 al 15% de TFs. Los *phyla* de parásitos que incluyen Chlamydiales y Spirochaetes comparten menos que 15 y 5% de TGs y TFs, respectivamente. Entre los 19 genomas de arqueas, los cuales comprenden 4 Crenarchaeota y 14 Euryarchaeota, encontramos que comparten entre el 7 y el 15% de TGs y menos que 3% de los TFs. El único parásito arqueano conocido, *Nanoarchaeum equitans*, comparte menos que el 1% de TGs y TFs de la TRN de *E. coli*.


Finalmente, 11 genomas de eucariontes, los cuales incluyen 2 Protistas, 4 Hongos, 2 Plantas, 1 Insecto y 1 Nematodo comparten entre 8 y 18% de los TGs con la excepción de los parásitos intracelulares obligados, tales como *Encephalitozoon cuniculi* que muestra solamente 2% de TGs. En contraste, se puede

<sup>16</sup> NOTA: Se usará de forma preferencial los conceptos **compartir, presencia o ausencia** de TFs, TGs e interacciones para los ortólogos detectados en los distintos genomas aquí analizados, en lugar de los conceptos **conservación y pérdida** de TFs, TGs e interacciones, ya que el uso de estas palabras implica que: 1) para el caso de la **conservación**, se refleja un proceso de divergencia evolutiva por especiación que mantiene los ortólogos y, en este trabajo no descartamos metodológicamente la transferencia horizontal de genes de TFs ni de TGs; y 2) para el caso de la **pérdida**, se refleja implícitamente un proceso de conservación y presencia de TFs y TGs en las especies ancestrales y, bajo el principio de evolución por Parsimonia (evolución por divergencia en el menor número de pasos), en este trabajo NO se hipotetiza que las TRNs de *E. coli* ni la de *B. subtilis* sean las ancestrales a todas las especies analizadas (Bacteria, Archaea y Eukarya). El uso de los conceptos de conservación y pérdida se aplica, en este trabajo, en aquellos casos donde las especies de comparación con las de referencia, tengan distancias filogenéticas cercanas y más preferencialmente a grupos filogenéticos completos, donde la existencia de un ancestria común en las TRNs es más probable. Así como también, se aplica para aquellos organismos donde se ha mostrado que existen fenómenos de reducción genómica masiva, resultado de estilos de vida parásito o simbionte y, que muestren la condición anterior de relación filogenética.

**Figura R-1A. Conservación de los componentes de la TRN (119 TFs y 850 TGs) de *Escherichia coli* K12 (con 4 248 genes) a través de los 3 dominios celulares.** Sobre el eje X se representan los 110 genomas no-redundantes ordenados por distribución filogenética [ver MÉTODOS-D y ANEXO 1 y 6A]. En el eje Y (sobre la izquierda) se representa el porcentaje de conservación de los elementos (TFs y TGs) de la TRN de referencia. Los valores CI (mostrados a la derecha del eje Y) representan una medida de conservación de los componentes de la TRN de un genoma con respecto a la conservación de sus genes. Un CI cercano a 0 indicaría que los componentes de la red regulatoria están pobemente conservados en comparación a la conservación del genoma, mientras que un CI cercano a 1 sugeriría que ambos, el TF y el TG están conservados en el mismo alcance. Un CI por arriba de 1 nos sugiere que el componente regulatorio (TFs o TGs) desde el organismo de referencia se encuentra conservado en mayor medida que el resto de su contenido genético.



**Figura R-1B. Conservación de los componentes de la TRN (99 TFs y 666 TGs) de *Bacillus subtilis* (con 4 079 genes) a través de los 3 dominios celulares.** Sobre el eje X se representan los 110 genomas no-redundantes ordenados por distribución filogenética [ver MÉTODOS-D y ANEXO 1 y 6B]. En el eje Y (sobre la izquierda) se representa el porcentaje de conservación de los elementos (TFs y TGs) de la TRN de referencia. Los valores CI (mostrados a la derecha del eje Y) representan una medida de conservación de los componentes de la TRN de un genoma con respecto a la conservación de sus genes. Un CI cercano a 0 indica que los componentes de la red regulatoria están poblemente conservados en comparación a la conservación del genoma, mientras que un CI cercano a 1 sugeriría que ambos, el TF y el TG están conservados en el mismo alcance. Un CI por arriba de 1 nos sugiere que el componente regulatorio (TFs o TGs) desde el organismo de referencia se encuentra conservado en mayor medida que el resto de su contenido genético.



observar que *Saccharomyces cerevisiae*, *Cyanidioschyzon merolae*, *Arabidopsis thaliana* y *Caenorhabditis elegans* comparten menos que 1% de los ortólogos de TFs de la TRN de *E. coli*, mientras que en el resto de los genomas eucariontes no se detectaron ortólogos de TFs de esta red.

Desde la perspectiva de *B. subtilis* [ver Figura R1B], pueden observarse mayores fluctuaciones en la distribución de los ortólogos detectados entre los genomas. Más de un 25% de los TFs y TGs se encuentran conservados en los linajes de Bacillales y Lactobacillales. Los organismos parásitos y endosimbiontes en Mollicutes, Chlamydia, Spirochetes y  $\alpha$  y  $\gamma$ -Proteobacterias comparten menos del 10% de los TGs y 5% de los TFs. La conservación de los TGs a través de las Proteobacterias es similar hasta *Bdellovibrio bacteriovorus* con respecto a la detectada en Bacillales, a pesar de las variaciones en las distancias filogenéticas entre estos grupos. A diferencia de la distribución de los TFs observada en *E. coli*, en *B. subtilis* se muestra una presencia casi constante en el número de TFs que se comparten en los diferentes grupos filogenéticos del dominio Bacteria. Aún cuando los porcentajes de ortólogos son similares, ello no implica que sean el mismo grupo de TFs. Más allá de los linajes bacterianos, donde encontramos que la conservación de los TFs de la TRN de *B. subtilis* disminuye rápidamente en arqueas y en eucariontes, sólo se detectó un TF compartido entre *S. cerevisiae*, *Candida albicans* y *Drosophila melanogaster* y dos TFs compartidos en *Dictyostelium discoideum*.

Desde la perspectiva de ambos genomas, se pueden observar tendencias similares en la distribución de ortólogos de los componentes de las TRNs de *E. coli* y *B. subtilis* a través de varios *phyla*. Lo primero que resalta es el rápido decremento en los ortólogos, tanto de TFs como de TGs. Inclusive, las especies filogenéticamente cercanas no presentan más de 30 a 60% de ambos componentes. Por otro lado, se observa que los TGs tienden a estar más conservados que los TFs conforme la distancia filogenética incrementa, mientras que en los linajes cercanos filogenéticamente, los TFs se encuentran más conservados que los TGs. Esto nos sugiere que la mayoría de la maquinaria regulatoria transcripcional en Bacteria puede ser linaje específico, lo cual refuerza una observación similar previa sugerida al nivel de taxa (65). Esta tendencia también nos sugiere que existen presiones de selección para mantener parte de la TRN en los organismos pertenecientes a un mismo *phyla* por medio de un grupo de reguladores comunes, mientras que el componente regulado (TGs) es el que cambiaría constantemente en estos casos.

El componente regulado (TGs) de las TRNs caracterizadas para *E. coli* corresponde al 20% y para *B. subtilis* al 16% de sus genomas completos; mientras que el componente regulador (TFs) corresponde al 3% en *E. coli* y al 2.5% en *B. subtilis*. En general, la medida de conservación (CI) [ver MÉTODOS-E y Figura R1A-B] para *E. coli* muestra que hay un incremento en la conservación de la proporción del componente regulado en los organismos en comparación al componente regulador, lo cual es mucho más notorio en los dominios Archaea y Eukarya. Desde el punto de vista de *B. subtilis*, aunque el decremento del CI en el componente regulador no es claro sino hasta linajes lejanos, la tendencia del componente regulado se puede observar más semejante a la detectada con *E. coli*. Lo anterior nos sugiere que el componente regulador ha tenido una mayor divergencia dentro de la evolución del genoma.

## 2. Evolución de los Reguladores Globales a través de las especies bacterianas.

Los Reguladores Globales (Global Regulators - GRs) regulan la actividad del 51% de la TRN conocida en *E. coli* (19). Estos TFs regulan grandes sistemas de operones que se ven sometidos a una regulación coordinada común, encaminada a la supervivencia de la bacteria en determinadas circunstancias ambientales extremas o, para realizar grandes ajustes metabólicos que le permitan adaptarse a cambios bruscos en las condiciones nutricionales. De esta forma, esperamos que estos GRs se encuentren conservados a lo largo del espectro filogenético. Consideramos la definición de GRs para *E. coli* de Martínez-Antonio y Collado-Vides (19), basados en el número de genes que regulan y algunos factores adicionales, tales como el número de co-reguladores y el número de condiciones en los que ejercen su actividad regulatoria. Dada la ausencia de suficiente información sobre *B. subtilis* para clasificar TFs sobre las mismas bases, consideramos como GRs a aquellos TFs que regulan el mayor número de genes en la TRN conocida (más de 20 interacciones regulatorias). Así, se conciben siete GRs en *E.coli*: CRP, FNR, IHF, FIS, ArcA, Hns y LRP, y ocho en *B. subtilis*: CcpA, AbrB, ComK, FUR, PhoP, TnrA, CodY y PurR.


Sorpresaivamente observamos que los ortólogos identificados para los GRs varían en su distribución filogenética y ninguno de ellos se identificó en eucariontes [ver Figura R2A-B]. Sin embargo, los TGs de estos GRs están conservados en los tres dominios celulares, sugiriendo que estos TGs podrían ser regulados en estos organismos por TFs parálogos, análogos o por otros mecanismos de regulación (i.e. *riboswitches*, RNAs pequeños, etc.).

Es interesante notar que ninguno de los GRs son parálogos a lo largo de toda la secuencia (no sólo al nivel de una porción de los dominios, como el dominio *Helix Turn Helix* de unión al DNA) entre *E. coli* [ver Figura R2A] y *B. subtilis* [ver Figura R2B]. Lo anterior indica que los TFs globales en organismos diferentes no comparten ancestros comunes cercanos. Esta observación podría implicar que los TFs globales evolucionan independientemente en diferentes linajes, en respuesta a los requerimientos en diferentes condiciones ambientales. De todos los GRs, sólo LRP y las subunidades de IHF (HimD o HimA) fueron detectadas en el dominio Archaea, sugiriendo que la gran parte de estos GRs se originaron de forma independiente en los linajes de Bacteria. Curiosamente, se observa que en algunos grupos de Proteobacteria, Firmicutes y Cianobacteria los ortólogos de CRP y FNR, los cuales son parálogos en *E. coli*, tienen una distribución alternativa, posiblemente indicando una sustitución de sus papeles funcionales en estos linajes. Otra posibilidad es que se haya transferido horizontalmente uno (o ambos) de los miembros de la familia CRP en diferentes organismos. Se ha reportado que los miembros de la familia CRP-FNR destacan en la respuesta de un amplio espectro a señales intracelulares y extracelulares, tales como AMP cíclico (cAMP), anoxia, estado redox, estrés oxidativo<sup>17</sup> y nitrosativo<sup>18</sup>, óxido nítrico, monóxido de carbono, 2-oxoglutarato,

<sup>17</sup> Estrés oxidativo (66). Es un estado de la célula en la cual se encuentra alterada la homeostasis óxido-reducción intracelular, es decir el balance entre prooxidantes y antioxidantes. Este desbalance se produce a causa de una excesiva producción de especies reactivas de oxígeno (EROs) y/o por deficiencia en los mecanismos antioxidantes, conduciendo a daño celular.


<sup>18</sup> En analogía al término “estrés oxidativo”, Hausladen y Stambler (66) han denominado “estrés nitrosativo” a la excesiva o desregulada formación del radical óxido nítrico (NO) y especies reactivas del Nitrógeno (ERNs) derivadas del mismo.

**Figura R-2A. Conservación de los Reguladores Globales de la TRN (7 GRs) de *Escherichia coli* K12 a través de los 3 dominios celulares.** Sobre el eje horizontal se representan los 110 genomas no redundantes ordenados por distribución filogenética [ver MÉTODOS-D y ANEXO 1 y 7A]. En el eje vertical (sobre la izquierda) se representa para cada uno de los 7 GRs la fila de distribución de los ortólogos detectados para el GR (el color negro significa presencia y el blanco significa ausencia); y en la fila de abajo, la distribución del porcentaje de ortólogos detectados de los TGs a los cuales regula con respecto al total reportados en *E. coli* (GR - #TGs). Una barra de correspondencia para los porcentajes representados por colores, se muestra en la base de la figura. Las funciones para cada GR fueron obtenidas de **RegulonDB** (<http://regulondb.ccg.unam.mx>).



GR	#TGs	Función sólo en regulación transcripcional
CRP	240	Regula el catabolito a catabolitos
IHF	160	Factor hospedero de integración-recombinación en DNA
FNR	112	Regula la reducción de nitrato y fumarato
ArcA	88	Regula la respiración aeróbica
FIS	76	Regula la transcripción del RNA ribosomal
LRP	55	Regula la respuesta a leucina
HNS	33	Regula la transcripción del DNA en varios estreses

**Figura R-2B. Conservación de los Reguladores Globales de la TRN (8 GRs) de *Bacillus subtilis* a través de los 3 dominios celulares.** Sobre el eje horizontal se representan los 110 genomas no-redundantes ordenados por distribución filogenética [ver MÉTODOS-D y ANEXO 1 y 7B]. En el eje vertical (sobre la izquierda) se representa para cada uno de los 8 GRs la fila de distribución de los ortólogos detectados para el GR (el color negro significa presencia y el blanco significa ausencia); y en la fila de abajo, la distribución del porcentaje de ortólogos detectados de los TGs a los cuales regula con respecto al total reportados en *B. subtilis* (GR - #TGs). Una barra de correspondencia para los porcentajes representados por colores, se muestra en la base de la figura. Las funciones para cada GR fueron obtenidas de DBTBS (<http://dbtbs.hgc.jp/>).



GR	#TGs	Función sólo en regulación transcripcional
CcpA	97	Regula la represión a catabolitos y la excreción de exceso de carbono
AbrB	72	Regula el crecimiento vegetativo, la fase estacionaria, la esporulación y la represión a catabolitos
ComK	47	Regula la competencia en la transducción de señales
PhoP	35	Regula las condiciones de reserva a fosfato
FUR	34	Regula la biosíntesis de sideróforos y la transcripción de ferri-sideróforos
TnrA	31	Regula la degradación de componentes que contienen nitrógeno
CodY	29	Regula a los genes ComK y SrfA en presencia de casaminoácidos
PurR	22	Regula la transcripción de purinas, mediante la regulación dependiente del nucleótido adenina

o temperatura (67). Para acompañar su papel funcional, los miembros de la familia CRP-FNR tienen módulos sensoriales intrínsecos, lo cual permite la unión de moléculas efectoras alostéricas, o tienen grupos protéticos para la interacción con la señal. De esta forma, la adaptabilidad regulatoria y la flexibilidad estructural representada en los ortólogos de las proteínas CRP-FNR han permitido la evolución de un importante grupo de TFs versátiles fisiológicamente [ver ejemplos en el **ANEXO 8A**].

En *B. subtilis*, solamente los GRs CcpA, FUR y PhoP se presentan en genomas distantes filogenéticamente, sugiriendo un origen antiguo comparado a la distribución de sus otros GRs. Finalmente, FIS, ArcA y HNS en *E. coli* tienen una distribución restringida a Proteobacterias, mientras que AbrB, ComK, CodY y PurR en *B. subtilis* se encuentran restringidas a los linajes de Bacillales y Lactobacillales. De lo que se podría inferir que estos GRs divergieron después de la separación entre las Proteobacterias y Firmicutes.

La distribución filogenética de LRP se extiende hasta Archaea y hacemos una breve discusión al respecto. LRP es el único GR homodimérico<sup>19</sup> que se encuentra bien conservado a través de los linajes en Procariontes. Los homólogos de LRP han sido previamente identificados en procariontes exclusivamente (68). La amplia distribución filética de los homólogos de LRP entre Archaea y Bacteria sugiere que un regulador del tipo LRP estuvo presente en el último ancestro común (Last Common Ancestor - LCA) de los dominios Bacteria y Archaea. No obstante, la distribución de reguladores del tipo LRP se ha visto que varían a través de los organismos (e.g. 20 copias en *Mesorhizobium loti*, 3 en *E. coli* y ninguna en las cepas de *Buchnera*, *Mycoplasma* y *Chlamydia*). Estos últimos son parásitos o endosimbiontes que dependen completamente de sus hospederos para el suplemento de amino ácidos y otros tipos de metabolitos. Estos organismos también tienen genomas reducidos, lo cual podrían explicar la ausencia de los miembros de la familia. A pesar de su conservación en varios *phyla*, aún en especies relacionadas cercanamente, su mecanismo de regulación global no se ha conservado, tal como se demuestra en el análisis del ortólogo LRP de *Haemophilus influenzae* (69) [ver **ANEXO 8B**].

Estas observaciones apuntan a la conclusión de que, aún en organismos del mismo *phyla*, no existen claras restricciones para mantener el mecanismo de regulación generalizada de los GRs, aún cuando los TFs estén conservados al nivel de secuencia (69) [ver **ANEXO 8C** donde se ejemplifica el caso de la sustitución de TFs (análogos) para llevar a cabo la regulación catabólica en *E. coli* (CRP) y en *B. subtilis* (CcpA)]. De esta forma, podemos inferir que el papel funcional y jerárquico de los TFs ortólogos en la TRN puede ser diferente o sustituible en cada organismo.

<sup>19</sup> NOTA: Recordemos que IHF es un regulador transcripcional global (GR) heterodimérico que requiere de la unión de dos subunidades para su estado activo en *E. coli*: **himA** y **himD** (21). En el presente estudio, hemos detectado la presencia de ambas subunidades diferencialmente, a partir del cual podemos puntualizar que no son similares sus patrones de distribución, incluso en algunas especies es opuesta, y la única subunidad que se detecta en Archaea es himA, mientras que himD se restringe a Bacteria.

### 3. Evolución de pares TF-TG en TRNs.

Se ha demostrado que los complejos de interacciones proteína-proteína, especialmente como pares, tienden a estar conservados o perdidos de una forma concertada a lo largo de diferentes proteomas (70-71). Dado que una interacción transcripcional involucra un TF y su TG, uno podría esperar que co-ocurran como pares a través del proceso evolutivo. De esta forma, implementamos una medida de distancia ( $D$ ) como se describe en MÉTODOS-F para realizar un análisis de pares de co-ocurrencia (TF y su TG). De esta forma, cada par del conjunto de las interacciones regulatorias transcripcionales de *E. coli* y *B. subtilis* puede comportarse como una de las tres categorías siguientes: **a)** tanto un TF y su TG co-ocurren, **b)** cuando un TF ocurre en más especies que su TG y, **c)** cuando un TG ocurre en más especies que su TF [ver ejemplos en la Figura R3A].

Idealmente, si la interacción regulatoria está co-ocurriendo en diversas especies, uno esperaría que  $D_{TF}$  y  $D_{TG}$  tiendan a cero, pero por varias razones, tales como eventos de transferencia horizontal, pérdida o duplicación de genes, así como también posibles errores involucrados en la detección de ortólogos, uno obtendría sesgos en la distribución de pares TF-TG co-ocurriendo. Para evaluar la influencia de estos factores en la distribución de los ortólogos detectados, y para determinar un umbral (*threshold*) para la identificación de pares TF-TG co-relacionados, usamos pares de genes en rutas metabólicas de la base de datos del KEGG (42) como un control [ver MÉTODOS-G y ANEXO 3A]. Es bien conocido que genes en la misma ruta metabólica a menudo co-ocurren (60-61, 72-73). Basados en los umbrales determinados para cada genoma, identificamos a los pares TF-TG co-ocurriendo, e incluimos al resto de las interacciones dentro de una de las dos clases ( $TF > TG$  y  $TF < TG$ ) basadas sobre el cálculo en que un  $D_{TF}$  es más alto o bajo que su  $D_{TG}$  [ver Figura R3B, MÉTODOS-G y ANEXO 3B].

La Tabla R1 de la Figura R3B muestra los Z-scores de conservación para cada categoría de pares TF-TG en ambos genomas, datos calculados sobre la comparación con las 1 000 TRNs generadas aleatoriamente [ver Figura R3-B, MÉTODOS-H y ANEXO 4A-B]. Puede observarse que hay una pequeña fracción de la TRN en ambos genomas que co-evoluciona a través de varios organismos. Sin embargo, la significancia de la co-ocurrencia desde la perspectiva de *B. subtilis* (*p-value* 0.0028) se observa relativamente más baja que en *E. coli* (*p-value* <0.0001) [ver Figura R3B-Tabla R1]. Tal observación debe ser evaluada en función de ciertos factores que no pueden verse reflejados directamente en el *p-value*, como el sesgo en el número de genomas secuenciados que conforman a Firmicutes comparado con el de Proteobacterias, así como la diferencia en el tamaño de las TRNs que son usadas, en cuyo caso es menor para la TRN de *B. subtilis*.

Una proporción igualmente aproximada de pares TF-TG se determinó en las categorías de  $TF > TG$  y  $TF < TG$  en ambos genomas [ver Figura R3B-Tabla R1]. Los Z-scores calculados en las categorías respectivas, sugieren que no existe una tendencia clara hacia la distribución de un  $TF > TG$  o hacia la de un  $TF < TG$  en ninguno de los dos genomas. Los Z-scores en cada caso corresponden a no más de 3-4 desviaciones estándar, excepto para el caso de las distribuciones  $TF < TG$  en *E. coli* (Z-score 3.68) [ver

Figura R3B-Tabla R1]. Esto demuestra que existe una restricción de co-ocurrencia para la mayoría de las interacciones entre un par TF y su TG.

Es importante hacer notar que la perspectiva de este análisis es diferente con respecto al análisis cuantitativo de la distribución de los elementos individuales (TFs y TGs) de la TRN de referencia. Esta perspectiva se localiza sobre el siguiente nivel de la evolución regulatoria, las interacciones. Específicamente, trata del entendimiento sobre la co-ocurrencia de los componentes que la conforman. De esta forma, las TRNs estudiadas aquí revelan que los pares de interacciones TF-TG no co-ocurren preferencialmente, en contraste a las interacciones del tipo proteína-proteína. Con excepción a una pequeña fracción significativa (que representa el 2%) de pares que co-ocurren en las TRNs analizadas (15 interacciones en ambos genomas), el análisis presente demuestra que las fuerzas de la selección natural podrían actuar de forma relativamente independiente para retener un TF y su TG. Es decir, los componentes de la interacción regulatoria transcripcional se pierden o ganan independientemente.

#### **4. Conservación de los regulones e interacciones conservadas de las TRNs a través de las especies bacterianas.**


La regulación de la actividad celular difícilmente está determinada por la participación de interacciones aisladas. La TRN tiende a estar interconectada y organizada en módulos funcionales. A su vez, existen muy pocos módulos que se encuentran separados enteramente del resto de la red (12, 30, 74). En los módulos funcionales existen patrones específicos de inter-regulación entre un TF y sus TGs para responder a diferentes condiciones y, según el enfoque de la organización de la TRN, éstos pueden ser reconocidos a distintos niveles. Derivado de los argumentos anteriores, esperamos que los grupos de interacciones caracterizadas al nivel de regulones (grupos definidos por el número total de TGs que son regulados por un solo TF) se encuentren conservados en un amplio espectro filogenético. Por otro lado, estamos interesados en conocer si existen ciertos procesos celulares que hayan mantenido su regulación transcripcional a partir de los mismos módulos funcionales desde las etapas tempranas de la divergencia bacteriana.

En la Figura R4, mostramos la conservación de interacciones regulatorias al nivel de regulones tanto para *E. coli* como para *B. subtilis* en los 110 genomas completos no redundantes. Dos enfoques de conservación son generados a partir de un análisis de agrupamiento (*clustering*) de regulones de las TRNs de referencia:

- 1) Un **agrupamiento horizontal** que representa la extensión de la TRN de referencia en cada uno de los 110 genomas, a partir del total de regulones que la componen [ver MÉTODOS-I].
- 2) Un **agrupamiento vertical** que representa la distribución de cada uno de los regulones a través de los 110 genomas [ver MÉTODOS-I].


En general, puede observarse que las TRNs de *E. coli* [ver Figura R4A] y de *B. subtilis* [ver Figura R4B] comparten un número limitado de regulones a través de los genomas analizados, aunque la conservación es mayor en linajes cercanos filogenéticamente. Comparamos la distribución de los genomas en el agrupamiento horizontal con la basada en la relación filogenética generada por el método de Brown *et al.* (58) y encontramos que varios linajes fueron agrupados apropiadamente en función de los porcentajes de conservación de los regulones.

Desde el agrupamiento horizontal, es interesante notar que los clados más cercanos a *E. coli* [ver Figura R4A], los cuales incluyen varias Proteobacterias, comparten alrededor del 40% de las interacciones regulatorias transcripcionales desde *E. coli*, excepto para organismos parásitos y endosimbiontes, los cuales fueron agrupados juntos y muestran una escasa conservación de la TRN. Las proteobacterias *Blochmannia floridanus*, el mollicute *Mesoplasma florum* y *Ureaplasma urealyticum*, las arqueas *Methanopyrus kandleri*, *Methanococcus jannaschi*, *Methanobacterium thermoautotrophicum*, *Halobacterium* sp, *Pyrococcus furiosus*, *Aeropyrum pernix*, *Nanoarchaeum equitans* y los 10 organismos eucarióticos analizados no muestran ninguna interacción regulatoria del tipo *E. coli*. Desde la perspectiva de *B. subtilis* [ver Figura R4B] los clados más cercanos comparten alrededor del 30% de las interacciones regulatorias



**Figura R-4A. Conservación de regulones (118 en total) de la TRN de *Escherichia coli* K12 a través de 110 genomas completos.** Se realizaron dos agrupamientos basados en los porcentajes de interacciones conservadas por cada regulón. El primer agrupamiento, que aquí denominamos **horizontal**, corresponde a la extensión de la TRN de referencia a través de los genomas analizados. Un segundo agrupamiento, denominado **vertical**, corresponde a la conservación que presentan los diferentes regulones que componen a la TRN a través de los genomas. Una barra de correspondencia en colores (abajo) representa el espectro de los porcentajes de interacciones detectadas para cada regulón por genoma (de 0% en blanco al 100% en rojo) [ver MÉTODOS-I y ANEXO 9A].

## ORGANISMOS



**Figura R-4B. Conservación de regulones (93 en total) de la TRN de *Bacillus subtilis* a través de 110 genomas completos.** Se realizaron dos agrupamientos basados en los porcentajes de interacciones conservadas por cada regulón. El primer agrupamiento, que aquí denominamos **horizontal**, corresponde a la extensión de la TRN de referencia a través de los genomas analizados. Un segundo agrupamiento, denominado **vertical**, corresponde a la conservación que presentan los diferentes regulones que componen a la TRN a través de los organismos. Una barra de correspondencia en colores (abajo) representa el espectro de los porcentajes de interacciones detectadas para cada regulón por genoma (de 0% en blanco al 100% en rojo) [ver MÉTODOS-I y ANEXO 9B].

transcripcionales, excepto algunos parásitos y endosimbiontes de los linajes *Bacillus* y *Lactobacillus*. Los mollicutes *U. urealyticum*, las arqueas *Picrophilus torridus*, *Pyrobaculum aerophilum*, *N. equitans* y los 10 organismos eucariontes analizados no muestran ninguna interacción regulatoria del tipo *B. subtilis*.

Las observaciones anteriores sugieren que pese a la escasa conservación de la TRNs, la regulación transcripcional refleja la historia evolutiva de la segregación de los principales grupos bacterianos, tal como se prueba con el uso de la distancia filogenética. Y por otro lado, que el patrón de conservación de las TRNs a través del espectro filogenético, provee una medida de distinción entre los estilos generales de vida, tales como organismos parásitos, simbiontes y de vida libre, así como también las diferencias que existen en la regulación transcripcional entre Bacteria y Archaea (REF).

En la agrupación vertical se puede observar que una fracción alta de los regulones de la TRN de *E. coli* [ver Figura R4A] se encuentran compartidos en un gran grupo de organismos, los cuales subyacen bajo TFs metabólicos y estructurales del tipo IscR, ArgR, AsnC, BirA, Crp, DnaA, Fnr, Fur, GlpR, Ihf, LexA, Lrp, NagC, OxyR, OmpR, PhoB, KdpE y RbsR [ver la **información disponible online** sobre la función detallada de cada uno de estos TFs y sus regulones]. Aún cuando estos regulones tengan un alto porcentaje de sus interacciones, ello no implica que las interacciones sean las mismas en los organismos donde se identifican. De esta misma forma, un regulón que posee un bajo porcentaje de sus interacciones en otros genomas, podría implicar que si bien el regulón no está muy conservado, es posible que las pocas interacciones que se mantienen en otros genomas sean las mismas.

Derivado de este razonamiento, se llevó a cabo otra estrategia para detectar las interacciones de regulación transcripcional conservadas en los organismos bacterianos. El análisis elaborado por el método DOLLOP y en base al principio de Parsimonia [ver MÉTODOS-J] sobre las predicciones de las TRNs desde *E. coli*, reveló que existe solamente un pequeño grupo de interacciones conservadas comunes entre diferentes *phyla* bacterianos, los cuales representan alrededor del 6% de la TRN de *E. coli*. Estas interacciones regulan importantes procesos celulares en *E. coli*, tales como síntesis de arginina, asparagina, biotina y ribosa, transporte de aminoácidos y hierro, disponibilidad de fosfato, procesos de replicación y el sistema de respuesta SOS, [ver **ANEXO 5** para más detalles sobre estas interacciones].

Por su parte, los regulones altamente conservados desde *B. subtilis* incluyen reguladores metabólicos y estructurales del tipo DnaA, LexA, HrcA, PerR, BirA, AzlB, YwfK, AhrC (ArgR), CcpA, FUR, ResD, YycF, PhoP, DegU y MntR [ver la **información disponible online** sobre la función detallada de cada uno de estos TFs y sus regulones]. Entre estos regulones conservados hay, al menos, dos TFs hipotéticos: YwfK y YycF cuya función es aún desconocida. Los patrones de conservación aquí generados podrían ser usados para entender y caracterizar estos TFs a través de la combinación de métodos experimentales y computacionales que puedan apoyar en la determinación de su función, tales como el contexto funcional de sus TGs, sus ortólogos en otros organismos o el análisis de sus bsDNA a través de *phylogenetic footprinting* de las regiones río arriba de los TGs en genomas cercanos.

Con la misma estrategia que para la TRN de *E. coli* [ver MÉTODOS-J], se detectó una menor proporción de interacciones conservadas entre diferentes *phyla* bacterianos desde la TRN de *B. subtilis*. Las

interacciones conservadas de la TRN de *B. subtilis* están involucradas de forma similar que en *E. coli* en la síntesis de arginina y biotina, transporte de managaneso, disponibilidad de fosfato, genes de respuesta al estrés por calor, funciones regulatorias globales, procesos de replicación y el sistema de respuesta SOS [ver **ANEXO 5** para más detalles sobre estas interacciones].

La conservación de algunos de los regulones detectados aquí, tales como ArgR, BirA y LexA han sido previamente reportados en varios *phyla* (32-33, 75). Sin embargo, el repertorio de regulones conservados que se detectan en este estudio, podría aumentar nuestro entendimiento en la conservación de específicos módulos funcionales, lo cual podría guiar a futuros estudios experimentales para caracterizarlos.

De esta forma, el análisis de conservación elaborado por grupos de interacciones, que a través del concepto de regulón pueden entenderse como un módulo funcional en la red, nos revela que la evolución de las TRNs ha experimentado grandes cambios, si bien no sabemos si también en su estructura, al menos sí en sus interacciones. Por otro lado, existen pocos pero bien conservadas interacciones que han regulado procesos estructurales, principalmente, desde etapas tempranas de la diversificación bacteriana.

## DISCUSIÓN GENERAL Y CONCLUSIONES

La complejidad de las redes de regulación transcripcional en los organismos bacterianos es ampliamente afectada por su adaptación al estrés ambiental que cambia dinámicamente en los nichos ecológicos. Por ejemplo, las bacterias entéricas, bacterias de suelo y otras bacterias de vida libre viven en ambientes complejos y tienen subsistemas de respuestas de censado a señales metabólicas y extracelulares (76). En contraste, el limitado espectro ecológico y la disgregación frecuente de la población en los patógenos obligados y simbiontes han resultado en un incremento en las tasas de deriva genética y restricciones selectivas que limitan las funciones en el censado extracelular, así como el número de los genes que utilizan para responder a estrés intracelular (77-79). Nuestros resultados indican que los estilos de vida de endosimbiontes así como de parásitos estrictos comparten solamente alrededor del 10% de los componentes ortólogos, y menos del 2% de las interacciones que conforman las TRNs de *E. coli* y *B. subtilis*. La pérdida de elementos regulatorios puede reflejar una relativa constancia intracelular en el ambiente del hospedero, lo cual permite a estos organismos tener una estructura regulatoria simplificada y tentativamente poco diversa (76, 80). Acorde a nuestros resultados, la pérdida de muchos ortólogos de los factores de transcripción, y no así de los genes blancos, podría ser la principal causa de estos cambios dramáticos en la TRN, como puede verse desde el escenario de los reguladores globales de *E. coli* y *B. subtilis*, que tienen una distribución limitada aún cuando modulan directamente la expresión de aproximadamente el 51% de los genes en *E. coli* (19).

Encontramos que la conservación de las redes de regulación transcripcional de *E. coli* y *B. subtilis* (en sus diversos niveles de organización) subyace a *grosso modo* a la historia evolutiva de las especies, y que se ve reflejada en su distancia filogenética y estilo de vida (29). Nuestros resultados muestran que los factores de transcripción de una especie particular, incluso entre especies cercanas, se encuentran menos conservados que los genes blancos conforme se incrementa la distancia filogenética. Esto sugiere que la regulación transcripcional de los genes cambia más rápido en la evolución que los genes en sí. Relacionado con esto, Maslov *et al.* (81) encontraron que la tasa de diferenciación evolutiva de las interacciones es mucho más rápida que la de los genes blancos y que la de sus interacciones de proteína. Adicionalmente, nuestro análisis de la co-ocurrencia de pares de interacciones regulatorias a través de los genomas indica tendencias diferentes en la conservación de pares TF-TG, mostrando significativamente que la tendencia de co-ocurrencia entre un TF y su TG es casi nula, es decir, que ambos componentes evolucionan de forma independiente en la estructura de las TRNs. No obstante esta tendencia, es claro que:

- a) *Cuando un TF está conservado en diferentes especies sin su correspondiente TG, esto podría implicar que el TF es requerido en la regulación de un diferente grupo de TGs que aquellos reportados en el genoma de referencia.*

**b) Cuando un TG es conservado y su TF se pierde, esto podría implicar que el TG es regulado por un factor análogo, homólogo o por otros tipos de regulación transcripcional, tales como riboswitches y RNAs pequeños.**

**c) Cuando un TF y su TG(s) se conservan en el genoma de interés, no necesariamente éstos interactúan.**

Ésto sugiere que el nivel de flexibilidad que las TRNs pueden imponer sobre la evolución de la regulación transcripcional de los organismos en diferentes ambientes es alto. Las razones y mecanismos evolutivos para las tendencias observadas en el presente trabajo necesitan ser analizadas en líneas de investigación derivadas de este estudio.

A pesar de la escasa conservación de las interacciones regulatorias a través de las especies, ciertas interacciones individuales han sido bien conservadas a través de diferentes *phyla* eubacterianos. Estas interacciones regulan procesos transcripcionales esenciales en Bacteria. De hecho, muchos de estos procesos han sido bien caracterizados y están relacionados directamente o indirectamente a la maquinaria estructural, transcripcional y traduccional de la célula, explicando la razón de su conservación en amplias distancias filogenéticas. Aún cuando el tipo de regulación (represor o activador) y que el sitio de unión al DNA pueda cambiar a través de los genomas, es razonable pensar que es importante mantener la regulación de estos procesos comunes con los mismos elementos, como en el caso de los reguladores BirA y DnaA, los cuales se asumen como un resultado de la ancestría común en todas las bacterias.

La red de regulación transcripcional parece evolucionar de manera puntual, con pérdida, recambio y ganancia de elementos específicos de las interacciones individuales. Probablemente esta evolución puntual juega un papel más importante que la pérdida y la ganancia de motivos y módulos completos de interacciones. Como Teichmann y Babu (82) reportaron previamente, muchas redes se han originado por evolución convergente y no por duplicación genética de circuitos ancestrales (83). De esta forma, con la excepción de una pequeña fracción de la TRN, puede inferirse que grandes proporciones de las TRNs han evolucionado en los organismos a través de extensos cambios y re-conexiones entre sus componentes.

Desde nuestro análisis comparativo, demostramos que los elementos individuales, los pares interactantes y los grupos de interacciones (regulones) de la regulación transcripcional no están conservados, incluso en especies relacionadas cercanamente. Esto refleja que en cada evento de especiación, en el que se requiere de la adaptación a nuevas condiciones intra y extracelulares, la regulación transcripcional es más flexible que el componente genético de los organismos para la adaptación fenotípica. De esta forma, este trabajo puede proveer una perspectiva de la flexibilidad de la red de regulación transcripcional en bacterias, lo cual contribuye al entendimiento de las bases transcripcionales de la variación natural.

## REFERENCES

1. The American Heritage® Dictionary of the English Language. 4<sup>th</sup> Edition. 2000.
2. Kirschner M. and Gerhart J. (1998) **Evolvability**. *Proc. Natl. Acad. Sci.* 95:8420-8427.
3. Alberts B., et al. **Molecular Biology of the Cell**. 4<sup>th</sup> Edition. 2002. Garland Science. New York, USA.
4. Savageau M.A. (1991) **Reconstructionist molecular biology**. *New Biol.* 3, 190-7.
5. Savageau M.A. (2001) **Design principles for elementary gene circuits: Elements, methods, and examples**. *Chaos* 11, 142-159.
6. Kauffman S.A. (1973) **Control circuits for determination and transdetermination**. *Science* 181, 310-8.
7. Bagley R.J., Farmer J.D., Kauffman S.A., Packard N.H., Perelson A.S., Stadnyk I.M. (1989) **Modeling adaptive biological systems**. *Biosystems* 23, 113-37.
8. Fell, D.A. and Wagner, A. (2000) The small world of metabolism. *Nat Biotechnol*, 18, 1121-1122.
9. Ouzounis, C.A. and Karp, P.D. (2000) **Global properties of the metabolic map of *Escherichia coli***. *Genome Res*, 10, 568-576.
10. Thieffry, D., Huerta, A.M., Perez-Rueda, E. and Collado-Vides, J. (1998) **From specific gene regulation to genomic networks: a global analysis of transcriptional regulation in *Escherichia coli***. *Bioessays*, 20, 433-440.
11. Guelzim N., Bottani S., Bourgine P. and Kepes F. (2002) **Topological and causal structure of the yeast transcriptional regulatory network**. *Nat Genet*, 31, 60-63
12. Shen-Orr, S.S., Milo, R., Mangan, S. and Alon, U. (2002) **Network motifs in the transcriptional regulation network of *Escherichia coli***. *Nat Genet*, 31, 64-68.
13. Oltvai Z.N. and Barabási A.L. (2002) **Systems biology. Life's complexity pyramid**. *Science* 298, 763-4.
14. Lewin, B. **Genes VII**. 2000. Oxford University Press. New York, USA.
15. Browning D.F. and Busby S.J.W. (2004) **The regulation of bacterial transcription initiation**. *Nat Rev Microbiol*, 2, 57-65.
16. Neidhardt F.C., et al. ***Escherichia coli* and *Salmonella*: Cellular and Molecular Biology**. Vol. 2, 2<sup>th</sup> Edition. 1996. ASM Press. Washington D.C., USA.
17. Teichmann, S.A. and Babu, M.M. (2004) **Gene regulatory network growth by duplication**. *Nat Genet*, 36, 492-496.
18. Albert R. and Albert-László B. (2002) **Statistical mechanics of complex networks**. *Rev Modern Phys*, 34, 47-97.
19. Martinez-Antonio, A. and Collado-Vides, J. (2003) **Identifying global regulators in transcriptional regulatory networks in bacteria**. *Curr Opin Microbiol*, 6, 482-489.

20. Herrgard, M.J., Covert, M.W. and Palsson, B.O. (2004) **Reconstruction of microbial transcriptional regulatory networks.** *Curr Opin Biotechnol*, 15, 70-77.
21. Salgado, H., Gama-Castro, S., Martinez-Antonio, A., Diaz-Peredo, E., Sanchez-Solano, F., Peralta-Gil, M., Garcia-Alonso, D., Jimenez-Jacinto, V., Santos-Zavaleta, A., Bonavides-Martinez, C. et al. (2004) **RegulonDB (version 4.0): transcriptional regulation, operon organization and growth conditions in *Escherichia coli* K-12.** *Nucleic Acids Res*, 32, D303-306.
22. Barabasi A.L. and Albert R. (1999) **Emergence of scaling in random networks.** *Science*, 286, 509-512.
23. Brown T.A. **Genomes.** 1<sup>th</sup> Edition. 1999. Wiley-Liss Press. New York, USA.
24. Paillard G. and Lavery R. (2004) **Analyzing protein-DNA recognition mechanisms.** *Structure*, 12, 113-22.
25. Ahmad S., Gromiha M.M., Sarai A. (2004) **Analysis and prediction of DNA-binding proteins and their binding residues based on composition, sequence and structural information.** *Bioinformatics*, 20, 477-86.
26. Zhang Y., Xi Z., Hegde R.S., Shakked Z., Crothers D.M. (2004) **Predicting indirect readout effects in protein-DNA interactions.** *Proc Natl Acad Sci U S A*, 101, 8337-41.
27. Yu, H., Luscombe, N.M., Lu, H.X., Zhu, X., Xia, Y., Han, J.D., Bertin, N., Chung, S., Vidal, M. and Gerstein, M. (2004) **Annotation transfer between genomes: protein-protein interologs and protein-DNA regulogs.** *Genome Res*, 14, 1107-1118.
28. Wilson, C.A., Kreychman, J. and Gerstein, M. (2000) **Assessing annotation transfer for genomics: quantifying the relations between protein sequence, structure and function through traditional and probabilistic scores.** *J Mol Biol*, 297, 233-249.
29. Babu, M.M., Luscombe, N.M., Aravind, L., Gerstein, M. and Teichmann, S.A. (2004) **Structure and evolution of transcriptional regulatory networks.** *Curr Opin Struct Biol*, 14, 283-291.
30. Yeger-Lotem, E., Sattath, S., Kashtan, N., Itzkovitz, S., Milo, R., Pinter, R.Y., Alon, U. and Margalit, H. (2004) **Network motifs in integrated cellular networks of transcription-regulation and protein-protein interaction.** *Proc Natl Acad Sci U S A*, 101, 5934-5939.
31. Fitch, W.M. (1970) **Distinguishing homologous from analogous proteins.** *Syst Zool*, 19, 99-113.
32. Rodionov, D.A., Mironov, A.A. and Gelfand, M.S. (2002) **Conservation of the biotin regulon and the BirA regulatory signal in Eubacteria and Archaea.** *Genome Res*, 12, 1507-1516.
33. Erill, I., Jara, M., Salvador, N., Escribano, M., Campoy, S. and Barbe, J. (2004) **Differences in LexA regulon structure among Proteobacteria through in vivo assisted comparative genomics.** *Nucleic Acids Res*, 32, 6617-6626.
34. Sharan, R., Suthram, S., Kelley, R.M., Kuhn, T., McCuine, S., Uetz, P., Sittler, T., Karp, R.M. and Ideker, T. (2005) **Conserved patterns of protein interaction in multiple species.** *Proc Natl Acad Sci U S A*, 102, 1974-1979.
35. Struhl, K. (1999) **Fundamentally different logic of gene regulation in eukaryotes and prokaryotes.** *Cell*, 98, 1-4.

36. Su Z., Olman V., Mao F. and Xu Y. (2005) **Comparative genomics analysis of NtcA regulons in cyanobacteria: regulation of nitrogen assimilation and its coupling to photosynthesis.** *Nucleic Acids Res*, 33, 5156–5171
37. Makita, Y., Nakao, M., Ogasawara, N. and Nakai, K. (2004) **DBTBS: database of transcriptional regulation in *Bacillus subtilis* and its contribution to comparative genomics.** *Nucleic Acids Res*, 32, D75-77.
38. Blattner F.R., et al. (1997) **The complete genome sequence of *Escherichia coli* K-12.** *Science*, 277, 1453-74.
39. Kunst F., et al. (1997) **The complete genome sequence of the gram-positive bacterium *Bacillus subtilis*.** *Nature*, 390:249-56.
40. Evans L., Feucht A. and Errington J. (2004) **Genetic analysis of the *Bacillus subtilis* sigG promoter, which controls the sporulation-specific transcription factor s<sup>G</sup>.** *Microbiology* 150, 2277-2287.
41. Feucht A., Evans L., and Errington J. (2003) **Identification of sporulation genes by genome-wide analysis of the s<sup>E</sup> regulon of *Bacillus subtilis*.** *Microbiology* 149, 3023-3034.
42. Kanehisa, M., Goto, S., Kawashima, S., Okuno, Y. and Hattori, M. (2004) **The KEGG resource for deciphering the genome.** *Nucleic Acids Res*, 32, D277-280.
43. Teichmann, S.A., Murzin, A.G. and Chothia, C. (2001) **Determination of protein function, evolution and interactions by structural genomics.** *Curr Opin Struct Biol*, 11, 354-363.
44. Chothia, C., Gough, J., Vogel, C. and Teichmann, S.A. (2003) **Evolution of the protein repertoire.** *Science*, 300, 1701-1703.
45. Bork, P., Dandekar, T., Diaz-Lazcoz, Y., Eisenhaber, F., Huynen, M. and Yuan, Y. (1998) **Predicting function: from genes to genomes and back.** *J Mol Biol*, 283, 707-725.
46. Lan, N., Montelione, G.T. and Gerstein, M. (2003) **Ontologies for proteomics: towards a systematic definition of structure and function that scales to the genome level.** *Curr Opin Chem Biol*, 7, 44-54.
47. Lopez, R., Silventoinen, V., Robinson, S., Kibria, A. and Gish, W. (2003) **WU-Blast2 server at the European Bioinformatics Institute.** *Nucleic Acids Res*, 31, 3795-3798.
48. Bateman, A., Birney, E., Durbin, R., Eddy, S.R., Howe, K.L. and Sonnhammer, E.L. (2000) **The Pfam protein families database.** *Nucleic Acids Res*, 28, 263-266.
49. Sonnhammer, E.L. and Koonin, E.V. (2002) **Orthology, paralogy and proposed classification for paralog subtypes.** *Trends Genet*, 18, 619-620.
50. Tatusov, R.L., Koonin, E.V. and Lipman, D.J. (1997) **A genomic perspective on protein families.** *Science*, 278, 631-637.
51. Huynen, M.A. and Bork, P. (1998) **Measuring genome evolution.** *Proc Natl Acad Sci U S A*, 95, 5849-5856.
52. Janga, S.C. and Moreno-Hagelsieb, G. (2004) **Conservation of adjacency as evidence of paralogous operons.** *Nucleic Acids Res*, 32, 5392-5397.

53. Li, W., Jaroszewski, L. and Godzik, A. (2002) **Tolerating some redundancy significantly speeds up clustering of large protein databases.** *Bioinformatics*, 18, 77-82.
54. Hegyi, H. and Gerstein, M. (2001) **Annotation transfer for genomics: measuring functional divergence in multi-domain proteins.** *Genome Res*, 11, 1632-1640.
55. Bornberg-Bauer, E., Beaussart, F., Kummerfeld, S.K., Teichmann, S.A. and Weiner, J., 3rd. (2005) **The evolution of domain arrangements in proteins and interaction networks.** *Cell Mol Life Sci*, 62, 435-445.
56. Wheelan, S.J., Marchler-Bauer, A. and Bryant, S.H. (2000) **Domain size distributions can predict domain boundaries.** *Bioinformatics*, 16, 613-618.
57. Eddy, S.R. (1996) **Hidden Markov models.** *Curr Opin Struct Biol*, 6, 361-365.
58. Brown, J.R., Douady, C.J., Italia, M.J., Marshall, W.E. and Stanhope, M.J. (2001) **Universal trees based on large combined protein sequence data sets.** *Nat Genet*, 28, 281-285.
59. Yang, S., Doolittle, R.F. and Bourne, P.E. (2005) **Phylogeny determined by protein domain content.** *Proc Natl Acad Sci U S A*, 102, 373-378.
60. Forst C.V. and Schulten K. (2001) **Phylogenetic Analysis of Metabolic Pathways.** *J Mol Evol*, 52, 471-489
61. Pinter R.Y., Rokhlenko O., Yeger-Lotem E. and Ziv-Ukelson M. (2005) **Alignment of metabolic pathways.** *Bioinformatics*, 21, 3401-3408.
62. Milo R., Shen-Orr S., Itzkovitz S., Kashtan N., Chklovskii D. and Alon U. (2002) **Network motifs: simple building blocks of complex networks.** *Science*, 298, 824-827.
63. de Hoon, M.J., Imoto, S., Nolan, J. and Miyano, S. (2004) **Open source clustering software.** *Bioinformatics*, 20, 1453-1454.
64. Felsenstein J. (1993). **PHYLIP (Phylogeny interface package)** version 3.6a2. Distributed by the author. Department of Genetics, University of Washington, Seattle.
65. Coulson, R.M., Enright, A.J. and Ouzounis, C.A. (2001) **Transcription-associated protein families are primarily taxon-specific.** *Bioinformatics*, 17, 95-97.
66. Hausladen A. and Stambler I.S. (1999) **Nitrosative Stress.** *Methods Enzymol*, 300, 389-395.
67. Körner H., Sofía H.J. and Zumft W.G. (2003) **Phylogeny of the bacterial superfamily of Crp-Fnr transcription regulators: exploiting the metabolic spectrum by controlling alternative gene programs.** *FEMS Microbiology Reviews*, 27, 559-592.
68. Brinkman, A.B., Ettema, T.J., de Vos, W.M. and van der Oost, J. (2003) **The Lrp family of transcriptional regulators.** *Mol Microbiol*, 48, 287-294.
69. Friedberg, D., Midkiff, M. and Calvo, J.M. (2001) **Global versus local regulatory roles for Lrp-related proteins: Haemophilus influenzae as a case study.** *J Bacteriol*, 183, 4004-4011.
70. Pagel, P., Mewes, H. W. and Frishman, D. (2004) **Conservation of protein-protein interactions - lessons from ascomycota.** *Trends Genet*, 20, 72-6.

71. Aravind, L., Watanabe, H., Lipman, D. J. & Koonin, E. V. (2000). **Lineage-specific loss and divergence of functionally linked genes in eukaryotes.** *Proc Natl Acad Sci U S A*, 97, 11319-11324.
72. Jeong, H., Tombor, B., Albert, R., Oltvai, Z.N. and Barabasi, A.L. (2000) **The large-scale organization of metabolic networks.** *Nature*, 407, 651-654.
73. Date, S.V. and Marcotte, E.M. (2003) **Discovery of uncharacterized cellular systems by genome-wide analysis of functional linkages.** *Nat Biotechnol*, 21, 1055-1062.
74. Mazurie, A., Bottani, S. and Vergassola, M. (2005) **An evolutionary and functional assessment of regulatory network motifs.** *Genome Biol*, 6, R35.
75. Makarova, K.S., Mironov, A.A. and Gelfand, M.S. (2001) **Conservation of the binding site for the arginine repressor in all bacterial lineages.** *Genome Biol*, 2, RESEARCH0013.
76. Cases, I., de Lorenzo, V. and Ouzounis, C.A. (2003) **Transcription regulation and environmental adaptation in bacteria.** *Trends Microbiol*, 11, 248-253.
77. Moran, N.A. (1996) **Accelerated evolution and Muller's ratchet in endosymbiotic bacteria.** *Proc Natl Acad Sci U S A*, 93, 2873-2878.
78. Itoh, T., Martin, W. and Nei, M. (2002) **Acceleration of genomic evolution caused by enhanced mutation rate in endocellular symbionts.** *Proc Natl Acad Sci U S A*, 99, 12944-12948.
79. Andersson, S.G. and Kurland, C.G. (1998) **Reductive evolution of resident genomes.** *Trends Microbiol*, 6, 263-268.
80. Wilcox, J.L., Dunbar, H.E., Wolfinger, R.D. and Moran, N.A. (2003) **Consequences of reductive evolution for gene expression in an obligate endosymbiont.** *Mol Microbiol*, 48, 1491-1500.
81. Maslov, S., Sneppen, K., Eriksen, K.A. and Yan, K.K. (2004) **Upstream plasticity and downstream robustness in evolution of molecular networks.** *BMC Evol Biol*, 4, 9.
82. Teichmann, S.A. and Babu, M.M. (2004) **Gene regulatory network growth by duplication.** *Nat Genet*, 36, 492-496.
83. Conant G.C. and Wagner A. (2003) **Convergent evolution of gene circuits.** *Nat Genet*, 34, 264-6.

# **Bacterial regulatory networks are extremely flexible in evolution**

Irma Lozada-Chávez, Sarath Chandra Janga and Julio Collado-Vides

*Programa de Geonómica Computacional, Centro de Ciencias Geonómicas, Universidad Nacional Autónoma de México, Apdo. Postal 565-A, Av. Universidad, Cuernavaca, Morelos, 62100 México.*

**Addresses for correspondence:** [ilozada@ccg.unam.mx](mailto:ilozada@ccg.unam.mx), [sarath@ccg.unam.mx](mailto:sarath@ccg.unam.mx)

**Keywords:** transcriptional regulatory network, conservation, regulon, prokaryotes, regulog, interactions

## ABSTRACT

Over millions of years the structure and complexity of the transcriptional regulatory network (TRN) in bacteria has changed, reorganized and enabled them to adapt to almost every environmental niche on earth. In order to understand the plasticity of TRNs in bacteria, we studied the conservation of currently known TRNs of the two model organisms *Escherichia coli K12* and *Bacillus subtilis* across complete genomes including Bacteria, Archaea and Eukarya at three different levels: individual components of the TRN, pairs of interactions and regulons. We found that transcription factors (TFs) evolve much faster than the target genes (TGs) across phyla. We show that global regulators are poorly conserved across the phylogenetic spectrum and hence transcription factors could be the major players responsible for the plasticity and evolvability of the TRNs. We also found that there is only a small fraction of significantly conserved transcriptional regulatory interactions among different phyla of bacteria and that there is no constraint on the elements of the interaction to co-evolve. Finally our results suggest that majority of the regulons in bacteria are rapidly lost implying a high order flexibility in the TRNs. We hypothesize that during the divergence of bacteria certain essential cellular processes like the synthesis of arginine, biotine and ribose, transport of amino acids and iron, availability of phosphate, replication process and the SOS response are well conserved in evolution. From our comparative analysis, it is possible to infer that transcriptional regulation is more flexible than the genetic component of the organisms and its complexity and structure plays an important role in the phenotypic adaptation.

## INTRODUCTION

Evolution is the result of variation and selection of the components and structure of organisms through time. Transcriptional regulation plays a prominent role in the expression of genetic information. Its primary role in microbial organisms is controlling the response to environmental changes, such as nutritional status and several stresses. An important idea emerging in post-genomic biology is that transcriptional regulation can be viewed as a complex network of interactions among diverse types of molecules like proteins, DNA and metabolites (1-4). In this work we try to assess the evolution of the structure and plasticity of the transcriptional regulatory network (TRN) across species at three distinct levels: individual components of the TRN, pairs of regulatory interactions and regulons (A regulon is defined as the group of all genes regulated by a transcription factor), through a comparative analysis of their conservation.

The basic unit of gene regulatory interaction consists of three components: a transcription factor (TF), its DNA binding site (operator) and the target gene (TG). Topologically, the TRN is complex because genes may be regulated by more than one TF and some TFs may control more than one gene through DNA binding site(s) (5-7). The TRN comprises a significant proportion of the genome in each organism and it constitutes a major component of the genetic basis for the evolution of diverse aspects of bacterial phenotypes. It is important to learn how the TRN evolves as it would enable us to study the molecular evolutionary ecology of regulatory diversification by examining both the extent and pattern of regulatory gene diversity, the phenotypic effects of molecular variation and their ecological consequences.

It is also important to recognize that, although abundant sequence data and complete genomes are available, the experimental determination of TRNs has been limited to a few organisms even in prokaryotes. Besides, there is no clear relationship between the presence of a TF, its TG and DNA binding site(s), and their structural and biochemical characteristics that could have been transferred between genomes. It is also difficult to evaluate a specific measure between sequence homology, function and interaction transfer for any two proteins involved

in a regulatory interaction (6,8,9). However, several groups have recently examined the transfer of regulatory interaction annotations from one organism to another using comparative genomic approaches (9,10). The transfer of such interactions involves assigning functional roles to TFs and TGs, based on protein sequence similarity and on the conservation of topological patterns of the TRN, such as motifs and modules (8,11).

The *Regulog* approach uses cross-species data to predict DNA-protein interactions across genomes. A TF and TG interaction in one species is predicted to occur in another species if their best sequence matches have been determined in the target group of genomes. The presence of just one of the components of the regulatory interaction is not enough to transfer the interaction annotation, it is necessary that both TF and its TG(s) are detected in another organism. Using this approach, Yu *et al.* (9) have shown that orthologous TFs and TGs of *Saccharomyces cerevisiae* and *Drosophila melanogaster* tend to share the same regulatory interaction if the eukaryotic TFs have minimal sequence identities of 30% to 60% depending on the protein family. More recently, Sharan *et al.* (12) associated functions to proteins using network-level conservation of protein-protein interactions in eukaryotic genomes. This implies that high sequence similarity does not necessarily mean that the function is conserved; but conservation at the level of network modules allows more confident function determination from the context. Therefore, the best matches are not always present within conserved protein clusters enforcing the notion that it is advantageous to increase the detection of conserved functions by including paralogous family expansion and contraction, and even gene loss. The high specificity of the predictions attained by Sharan *et al.* can be maintained because conservation is evaluated in the context of a protein interaction subnetwork and not independently for each interaction. However, it has been shown that the patterns of conservation between protein-protein interactions *versus* protein-DNA interactions is different (9), and that the transcriptional regulatory logic differs radically between Eukaryotes and Prokaryotes (13). As a consequence, the performance of transcriptional interaction mapping methods cannot be currently assessed at a large scale (7,9).

Given the increasing number of sequenced genomes, it is possible and quite important to have a broader perspective of the evolution of TRNs by mapping the changes in the components of the regulatory interactions, which might differ from the common reconstruction of the metabolic, structural and some transcriptional histories of the organisms. Understanding the evolution of TRNs will not only improve our insight over the biological constraints different organisms have acquired over time but also enable us to decipher the basic design principles underlying them. Besides, one can reconstruct a regulatory history from the core of the transcriptional regulatory interactions that have been shared in the cellular processes of bacteria.

We used the TRNs of two different model Bacteria. One of these is the TRN of the gram-negative bacterium *Escherichia coli* K12 contained in RegulonDB, which is probably the best known in bacteria (14). This database contains experimental information corresponding to nearly 20% of the TRN of *E. coli* (5). The second best studied Prokaryote in terms of transcriptional regulation is the gram-positive *Bacillus subtilis*. We obtained the complete set of regulatory interactions in this bacterium documented in DataBase of Transcriptional regulation in *Bacillus Subtilis* (DBTBS) (15). It is interesting to note that even though both are free living bacteria and require similar concentrations of oxygen and temperature levels, *E. coli* has adapted to thrive inside its host while *B. subtilis* has adapted to soil environments. In this work we used a modified version of the Regulog approach described above to identify the interaction pairs and regulons of these networks through a comparison against complete genomes of Bacteria, Archaea and Eukarya.

## MATERIALS AND METHODS

**Protein sequence collection.** A total of 204 completely sequenced genomes, including *Escherichia coli* K12 and *Bacillus subtilis*, were downloaded from the Kyoto Encyclopedia of Genes and Genomes (KEGG, <ftp://ftp.genome.ad.jp/pub/kegg/genomes/>) (16). See Table 1 in the supplementary material for details about the 204 completely sequenced genomes used in this study.

**Interaction Data.** We obtained the transcriptional regulatory interactions of *E. coli* K12 from RegulonDB version 4.0 (14), which compiles experimental information extracted from the literature. We also obtained the regulatory interactions of *B. subtilis* from DBTBS (15). We only considered regulatory interactions where regulators and target genes encode a polypeptide. Hence, interactions involving tRNA and other non-polypeptide coding target genes were ignored. Likewise, there are some transcription factors that activate and repress the same target gene due to the presence of more than one DNA binding site (e.g. Crp regulating *galE* as activator or repressor depending on two different DNA binding sites); we considered them as redundant interactions and only one interaction was used to represent them in the final dataset. Therefore, a total of 1678 non-redundant regulatory interactions that represent 119 TFs acting on 850 TGs were included in this work for *E. coli*. While a total of 785 non-redundant interactions representing 99 TFs affecting 666 TGs were included from the *B. subtilis* TRN.

**Detection of potential TFs and TGs across species.** It has been extensively reported that i) duplication of sequences, ii) divergence and iii) recombination are major sources of functional variation in protein evolution (17,18). However, it is important to note that the definition of “function” has often been vague and different approaches have been considered in comparative genomics (19-21). In this work, we assigned functional roles to TFs and TGs in other genomes by using an intersection of three criteria for the detection of orthologous proteins: **a)** bi-directional best hits (BDBHs), **b)** coverage in the BLASTP (22) alignment and **c)** detection of PFAM (23) conserved domains.

Orthologs are defined as proteins in different species that evolved from a common ancestor by speciation (24) and usually have the same function. Proteins that recently evolved from a

common ancestor by duplication previous to any speciation event are called “outparalogs” and hence are less likely to maintain the same function (25). By contrast, “inparalogs” are defined as those which have evolved by gene duplications that happened after the speciation event and are more likely to conserve their function. Operationally, both inparalogs and orthologous sequences are usually defined as best-matching homologs or bi-directional best hits (BDBHs) in another organism (26-28). Sequences in the same genome with more than 95% identity estimated with the CD-HIT program (29) were considered in this work as “inparalogs” and grouped into clusters. To identify orthologs we use the BDBHs definition through depurated genomes at 95% identity, with a significant BLASTP E-value ( $\leq 10^{-3}$ ) using the WU-BLAST program (22). However, functional assignment is not yet complete with this approach since identifying orthologs for transcription factors is not always straightforward.

It is well known that conserved domains inside a protein determine their specific function and that these can represent evolutionary units especially for proteins with more than one domain where the pattern of functional conservation is more complex. Therefore, proteins are more likely to share functions if they contain the same domains in a similar arrangement (20,30,31). However, it is very important to consider that an increase in the number of domains can change the original function of a protein (32). We defined the conserved domains for all sequences analyzed in this work by Hidden Markov Models (HMM) taken from PFAM version 10 (23), using the HMMER 2.3.1 program (33) with an E-value of  $\leq 10^{-3}$ . In addition, we required that at least 70% of the PFAM model is covered by the sequence.

Operationally we identified orthologs as those proteins that satisfy the following four conditions:

1. Sequences of the target genome that have a bi-directional best hit in the query genome with a significant BLASTP E-value ( $\leq 10^{-3}$ ).
2. At least 70% of the query sequence is included in the BLASTP alignment.
3. Target sequences share the PFAM domains of their query counterparts. Target sequences having one or more domains which match the orientation and arrangement to that of the query sequence and do not increment the total size of the protein in more than 100 residues were also considered in the analysis.

4. All the sequences included previously in the inparalog cluster were considered candidates that maintain the function only if the conditions 1, 2 and 3 are true for the representative sequence of the cluster.

We predicted the orthologs and PFAM domains of 119 TFs and 850 TGs of the TRN of *E. coli*, 99 TFs and 666 TGs of the TRN of *B. subtilis* as well as for the rest of the proteins from the complete genomes of *E. coli* and *B. subtilis* across the complete genomes of 175 bacteria, 19 archaea and 10 eukaryotes.

**Data Management.** To facilitate the display of results, we only show 110 complete genomes in all the figures, obtained by filtering out strains and species of the same bacterial genus keeping the strain or species with the maximum number of genes among a given genera of organisms. The evolutionary distance from *E. coli* and *B. subtilis* to all organisms was obtained according to the evolutionary branching process previously reported by Brown *et al.* (34). The evolutionary distance between any two organisms is related to the sum of the distances between each organism and its closest common ancestor.

**Conservation of orthologs.** To normalize the extent of conservation of the components (TFs and TGs) of the regulatory network in comparison to the total genome, we devised a simple metric called Conservation Index (CI) defined as

$$\mathbf{CI} = (x / \mathbf{TC}) / (y / \mathbf{GC})$$

Where  $x$  is the number of orthologs present in the target genome from the total number of components ( $\mathbf{TC}$  = TFs or TGs) of the TRN under consideration, and  $y$  is the total number of orthologs detected in the target genome from all protein coding genes ( $\mathbf{GC}$ ) in the genome under consideration, which in the case of *E. coli* would stand at 4248 and 4079 for *B. subtilis*. Therefore, CI is a measure of conservation of the components of the TRN of a genome pondered respect to the conservation of its genes. A CI near to 0 would indicate that the regulatory network components are poorly conserved in comparison to the genomic conservation, while a CI close to 1 would suggest that both the TF and TG are conserved to the same extent.

**Prevalence of TF-TG orthologous pairs across genomes.** The huge differences in genome size and gene content across Bacteria, Archaea and Eukarya, or between parasitic, symbiotic and free living organisms, can introduce bias when calculating the frequency distribution of the shared regulatory interactions across organisms. To correct for this problem, a factor of distance ( $D$ ) was considered for weighting the presence or absence of transcriptional regulators and their target genes across genomes:

$$D_X = A' / (A' + A \cap B) \text{ and } D_Y = B' / (B' + A \cap B)$$

$$\text{Where } A' = A - (A \cap B) \text{ and } B' = B - (A \cap B)$$

For the transcription factor TF- $X$  which regulates a target gene TG- $Y$ ,  $A$  denotes the set of all organisms from 110 non-redundant genomes in which an ortholog is found for TF- $X$  and  $B$  denotes the set of all organisms in which an ortholog is seen for TG- $Y$ .  $A'$  represents the subset of organisms which has an ortholog for  $X$  but not for  $Y$  and  $B'$  represents the subset of organisms for which an ortholog of  $Y$  is found but not  $X$ .  $A \cap B$  represents the set of organisms in which both orthologs are found. As an example, consider the case of an interacting pair, TF- $X$  and TG- $Y$ , where the TF distance ( $D_x$ ) is higher than TG distance ( $D_y$ ) because TF contains a higher number of orthologs than the TG. Clearly,  $D_x$  should contain most of the orthologs corresponding to that of the  $D_y$ , and the unique number in the  $D_y$  ( $B'$ ) ought to be very small. In the limit, if the  $D_y$  has no unique orthologs relative to the  $D_x$ , the distance  $D_y$  would reach zero. A similar procedure for weighting has been used by others in the past, but focusing on domain contents (35).

The distances for each pair of TF and TG for the complete TRNs generated by the above approach were classified into three classes: a) TF and TG co-occur and hence the TF is likely to regulate the TG ( $D_{TF} = D_{TG}$ ), b) TF is more conserved than TG ( $D_{TF} > D_{TG}$ ) and c) TG is more conserved than TF ( $D_{TF} < D_{TG}$ ) based on pre-defined thresholds (see below and supplementary material Method 1). To evaluate the statistical significance of the conservation of the regulatory interactions in these three different classes, we compared against 1000 randomly constructed regulatory networks for *E. coli* and *B. subtilis* each composed of the same number of interactions as the original TRNs but by switching the edges while maintaining the degree of each node the same as in the known TRN. It should be noted that this method of randomization preserves the in and out degree of the node and hence

topologically resembles known TRNs. In the entire analysis we excluded the interactions where TFs are auto-regulated as they would generate a bias when calculating the co-occurrence effect of TF-TG pairs. So the final set of interactions analyzed in this approach included 1620 TF-TG pairs in *E. coli* and 738 TF-TG pairs in *B. subtilis*.

**Clustering the conserved interactions.** For each TF in *E. coli* and *B. subtilis*, we calculated the percentage of total interactions conserved in its regulon across genomes. To represent this distribution we clustered by the extent of TRN and regulon conservation using Centroid Linkage Clustering method with an Uncentered Correlation as distance metric from the Cluster program (36). Other distance metrics were also evaluated but were not found to be significantly different in their ability to group lineages and regulons. Clustering data represents 118 regulons in *E. coli* and 93 regulons in *B. subtilis* conserved across genomes.

## RESULTS

### Conservation of TFs and TGs across species

Based on experimental information from 119 TFs and 850 TGs in *Escherichia coli* K12 and 99 TFs and 666 TGs in *Bacillus subtilis*, forming the components of their respective TRNs, we predicted their counterparts in 204 complete genomes, including 175 bacteria, 19 archaea and 10 eukaryotes (see Table 1 and Figure 1 in supplementary material for details). Figure 1 shows the distribution of orthologous conservation of the components (TFs and TGs) of the TRN from *E. coli* and *B. subtilis* across 110 non-redundant genomes representing 23 different phyla of the three cellular domains based on the phylogenetic reconstruction from Brown *et al.* (34).

From the perspective of *E. coli* (Figure 1a), the closest phylum includes 76 different Proteobacteria grouped from five subdivisions (15 α, 10 β, 42 γ, 4 δ and 5 ε). The extent of conservation in these groups is the highest of all analyzed phyla, where just over 30% of both TFs and TGs were conserved with the exception of parasitic and endosymbiotic organisms, which share only 10% of TFs and 20% TGs of the TRN from *E. coli*. Firmicutes from four different classes (10 Mollicutes, 22 Bacillales, 15 Lactobacillales and 4 Clostridia) were included too, which were found to have 20-30% of conserved TGs and 10-20% of conserved TFs, with the exception of parasitic and endosymbiotic organisms from Mollicutes, Mycobacterium, Tropomyces, which present less than 5% conservation of both TFs and TGs. Similar fractions of orthologs were detected in Actinobacteria as in Firmicutes. Other phyla like Bacteroidetes, Fusobacteria, Plactomyces, Cyanobacteria, Deinococci, Aquificae and Thermotogae share 10-25% of TGs and 5-15% of TFs. Parasitic phyla that include Chlamydiae and Spirochaetes have less than 15% and 5% of conserved TGs and TFs respectively. Among the 19 archaeal genomes which comprise 4 Crenarchaeota and 14 Euryarchaeota, we found 7-15% TGs and less than 3% of the TFs. The only known archaeal parasite, *Nanoarchaeum equitans* shares less than 1% TGs and TFs. Finally, 11 eukaryotic genomes which included 2 Protists, 4 Fungi, 2 Plants, 1 Insect and 1 Nematode share between 8 and 18% of TGs with the exception of the obligate intracellular parasite *Encephalitozoon cuniculi* that shows only 2% of TGs. Only *Saccharomyces cerevisiae*, *Cyanidioschyzon merolae*, *Arabidopsis thaliana* and *Caenorhabditis elegans* contain less than 1% of TF orthologs to those in *E. coli*.

From the perspective of *B. subtilis* (Figure 1b), although there seem to be fluctuations in the distribution of orthologs across genomes, more than 25% of TFs and TGs were found conserved in the Bacillus and Lactobacillus lineages. Parasitic and endosymbionts organisms in Mollicutes, Chlamydia, Spirochete and  $\alpha\gamma$  Proteobacteria share less than 10% of the TGs and 5% of TFs. Conservation of the TFs and TGs across proteobacteria seems to be roughly constant, despite variations in phylogenetic distances with respect to *B. subtilis* until *Bdellovibrio bacteriovorus*. Beyond bacterial lineages we found that the conservation of the TFs drops off rapidly with no TFs conserved in Eukarya.

Irrespective of the variations in the conservation of the TFs and TGs across various phyla from the perspective of both the genomes, we observe that TGs tend to be more conserved than TFs as the phylogenetic distance increases while in closely related lineages TFs seem to be more conserved than TGs. This suggests that the majority of the transcriptional regulatory machinery in Bacteria could be lineage specific strengthening a previous observation made at the level of taxa (37). The TGs of the experimentally characterized TRN of *E. coli* correspond to 20% of its complete genome, while the characterized TFs correspond to 3%. In general, the measure of conservation (CI) (see Methods and Figure 1) shows that there is a steady increase in the conservation of the proportion of regulated component (TGs) of the cell in comparison to the regulatory component (TFs). Another interesting observation is that there is a certain fraction of the regulated component which is conserved in all lineages irrespective of the extent of genomic conservation of genes. However, it should be noted that the conserved fraction need not necessarily correspond to the same set of genes. From the view point of *B. subtilis*, although the decrease in TF conservation with phylogenetic distance is not as clear until far off lineages, the distribution of TG conservation seem to be more like that of *E. coli*.

### **Evolution of Global Regulators across bacterial species**

Here we consider the definition of Global Regulators (GRs) for *E. coli* from Martínez-Antonio and Collado-Vides (5), based on the number of genes they regulate and additional factors, such as the number of co-regulators and the number of conditions. Due to the absence of sufficient information for *B. subtilis* to classify TFs on the same basis, we considered those TFs as GRs which regulate the highest number of genes in the known TRN (more than 20

regulatory interactions). GRs regulate the activity of 51% of the known TRN in *E. coli* (5), so we aimed at understanding the conservation spectrum of these genes. There are seven GRs in *E. coli*: Crp, Fnr, Ihf, Fis, ArcA, Hns and Lrp and eight in *B. subtilis*: CcpA, AbrB, ComK, Fur, PhoP, TnrA, CodY and PurR.

The predicted orthologs of GRs vary in their extent of conservation across the phylogenetic spectrum, although none of them seem to be conserved in eukaryotes (see Figure 2a and b). However, their TGs are conserved in the three cellular domains suggesting that these TGs could be regulated in those organisms by analogous or paralogous TFs. It is interesting to note that none of the global transcription factors are homologously related at the sequence level between *E. coli* and *B. subtilis*, indicating that global TFs need not be conserved among phylogenetically distant genomes. This observation could imply that global TFs evolve in different lineages independently, according to the requirements in different conditions in which the organisms dwell. Of all the GRs only Lrp and the Ihf subunits (HimD or HimA) were found to occur in Archaea suggesting that most of these GRs originated in bacterial lineages. Curiously, orthologs of Crp and Fnr, which are paralogs in *E. coli*, seem to have an alternating distribution beyond Proteobacteria, in Firmicutes and Cyanobacteria, possibly indicating a substitution of their roles in these lineages or horizontal gene transfer of one of the members of the Crp family from one to another. In *B. subtilis* only the GRs, CcpA, Fur and PhoP seem to show their presence in phylogenetically distant genomes, suggesting an ancient origin compared to its other GRs. Finally, Fis, ArcA and Hns in *E. coli* have a limited distribution in other bacterial species, specifically restricted to Proteobacteria, while AbrB, ComK, CodY and PurR in *B. subtilis* are restricted to Bacillus and Lactobacillus lineages. A recent work in this direction shows the poor conservation of the hubs in regulatory networks of prokaryotic genomes (38).

The case of the phylogenetic distribution of Lrp extending to Archaea, needs further discussion as it is the only monomeric GR that is well conserved across lineages. Previously, homologs of Lrp-like transcriptional regulators were identified although their presence was detected only in Prokaryotes (39). The wide phyletic distribution of Lrp homologs among Archaea and Bacteria suggests that an Lrp-type regulator was present in the last common ancestor of Bacteria and Archaea. Nevertheless the distribution of Lrp-type regulators seems to vary across organisms (e.g. 20 copies in *Mesorhizobium loti*, 3 in *E. coli* and none in the

strains of *Buchnera*, *Mycoplasma* and *Chlamydia*). The latter ones are bacterial endosymbionts and completely depend on their host for the supply of amino acids and other key metabolites. They have reduced genomes which could explain the absence of Lrp members. In spite of their conservation in various phyla, even in closely related species its global regulatory mechanism does not seem to be conserved as has been demonstrated by the analysis of the Lrp ortholog of *Haemophilus influenzae* (40). These observations point to the conclusion that even in organisms of the same phyla there is no real constraint for the conservation of the functions of GRs, although the GRs themselves might be well conserved at the level of sequence. Hence providing insight that at the level of transcriptional regulatory machinery orthologous genes in different genomes could play different functional roles.

### **Evolution of TF-TG pairs in TRNs**

We implemented a distance ( $D$ ) as described in Methods for a comparative analysis of the orthology distribution of a TF and its TG. As mentioned earlier, we studied the conservation of the transcriptional regulatory interactions across bacterial species by assigning each TF-TG pair to one of the three different categories: a) when a TF and its TG are both present or absent together, b) when a TF is conserved in more species than its TG and c) when a TG is conserved in more species than its TF (see examples in Figure 3). Ideally if the regulatory interaction is co-occurring across species, one would expect that  $D_{TF}$  and  $D_{TG}$  should both be equal to zero, but for several reasons like horizontal transfer events, loss or duplication of genes and errors involved in the detection of orthologs, one could obtain biases in the distribution of co-evolving TF-TG pairs. In order to take into account these factors and to determine a threshold for identifying co-evolving TF-TG pairs we used pairs of genes in metabolic pathways from KEGG (16) as a control (see supplementary material for details about generation of thresholds). It is known that genes in the same metabolic pathway often co-evolve and are well conserved (41,42). Based upon the thresholds determined for each genome we identified the co-evolving TF-TG pairs and then included the rest of the interactions into one of the two classes based on whether  $D_{TF}$  is higher or lower than  $D_{TG}$ .

Table 1 shows the Z-scores of conservation for each category of TF-TG pairs in both the genomes computed upon comparing with the randomly generated TRNs as described earlier (see Methods). It can be seen that there is a relatively small fraction of the TRN in both genomes which is conserved and co-evolving across genomes. However the significance of co-evolution from the perspective of *B. subtilis* seems to be smaller than in *E. coli* as seen from the p-value (see table), which might be due to the under representation of the number of genomes in Firmicutes compared to Proteobacteria or due to the difference in the size of the TRNs being used in the two genomes. A roughly equal proportion of TF-TG pairs occur in the categories of  $TF > TG$  and  $TF < TG$  in both genomes (see Figure 2 in supplementary material). The Z-scores in the respective categories suggest that there is no clear tendency for either  $TF > TG$  or  $TF < TG$  in both the genomes, as the Z-scores in each case correspond to no more than 3-4 standard deviations except that of  $TF < TG$  in *E. coli*. This indicates that there is no constraint on the co-evolution of a TF and its TG in an interacting pair for majority of the interactions. Note that this is different from the quantitative analysis of the conservation of individual elements (TFs and TGs) conserved from the TRN as here we are interested in the co-evolution of the pairs of interactions. The above analysis suggests that there is a small but well conserved fraction of the TRN which is present in diverse phyla and that the majority of the TF-TG pairs evolve independently.

### Conservation of regulons across bacterial species

In Figure 4, we show the conservation of regulatory interactions at the level of regulons for both *E. coli* and *B. subtilis* across 110 non-redundant complete genomes representing various phyla, clustered horizontally by the extent of TRN conservation across genomes and vertically by the extent of regulon conservation (see Methods). In general, it can be seen that the TRNs share few regulons across the phylogenetic spectrum, although the conservation is more in closely related lineages.

We compared the distribution of the genomes in the horizontal axis which was based on the extent of conservation of the TRNs, with that of the phylogenetic distribution generated by the method of Brown *et al.* (34) and found that several lineages were appropriately grouped, suggesting that TRN conservation can aid in segregating the major bacterial kingdoms and

that phylogenetic distance provides a measure of the extent of TRN conservation. It is interesting to note that the clades closest to *E. coli* (Figure 4a), which includes several Proteobacteria, share around 40% of the transcriptional regulatory interactions from *E. coli* except for several parasitic and endosymbiotic organisms, which were grouped together and show poor conservation of the TRN. The Proteobacteria *Blochmannia floridanus*, mollicutes *Mesoplasma florum* and *Ureaplasma urealyticum*, the Archaea *Methanopyrus kandleri*, *Methanococcus jannaschi*, *Methanobacterium thermoautotrophicum*, *Halobacterium* sp, *Pyrococcus furiosus*, *Aeropyrum pernix*, *Nanoarchaeum equitans* and the ten analyzed eukaryotic organisms do not seem to share any regulatory interaction with *E. coli*.

From the perspective of *B. subtilis* (Figure 4b) the closest clades share around 30% of the transcriptional regulatory interactions except for some parasitic and endosymbiotic organisms from the Bacillus and Lactobacillus lineages. The Mollicute *U. urealyticum*, the Archaea *Picrophilus torridus*, *Pyrobaculum aerophilum*, *N. equitans* and the ten analyzed eukaryotic organisms do not seem to share any regulatory interaction with the TRN of *B. subtilis*.

The horizontal distribution in Figure 4 which shows the conservation of regulons in the respective TRNs points out that certain regulons are widely conserved across species, although this fraction seems to be higher from the perspective of *E. coli*. Highly conserved regulons from *E. coli*'s TRN include metabolic and structural components like IscR, ArgR, AsnC, BirA, Crp, DnaA, Fnr, Fur, GlpR, Ihf, LexA, Lrp, NagC, OxyR, OmpR, PhoB, KdpE and RbsR. Within these conserved regulons there is only a small set of ancient conserved interactions among different bacterial phyla, which represent around 6% of the TRN of *E. coli*. These interactions regulate important cellular processes in *E. coli* such as synthesis of arginine, asparagine, biotin and ribose, transport of amino acids and iron, availability of phosphate, replication process and the SOS response system (see Table 2 in supplementary material for additional information about these anciently conserved interactions from both the genomes). Highly conserved regulons from *B. subtilis* include DnaA, LexA, HrcA, PerR, BirA, AzlB, YwfK, AhrC (ArgR), CcpA, Fur, ResD, YycF, PhoP, DegU and MntR. These regulons are involved in the regulation of the synthesis of arginine and biotin; transport of manganese, availability of phosphate, heat shock response genes, global regulatory functions, replication process and the SOS response system. Some of the conserved regulons found here such as ArgR, BirA and LexA have been previously reported to be found in various phyla

(6,43,44). However, this repertoire of conserved regulons should enhance our understanding of the conservation at the level of regulons and guide further experimental studies to characterize them.

For example, among these conserved regulons there are at least two hypothetical TFs: YwfK and YycF whose function is yet unknown. These conserved patterns at the level of regulons could be used to understand and characterize these TFs through a combination of experimental and computational methods thereby aiding in the determination of their function. Computationally, one can identify the function of the TF from the functional context of its regulated genes or their conserved orthologs in a way similar to what has been demonstrated earlier for several TFs from genomic context (45). Regulatory binding sites can be identified through a phylogenetic foot printing analysis of the upstream regions of putative target genes in closely related genomes. Experimental evidence added to computational predictions can elevate the quality of the predictions as has been shown in the case of LexA regulon (6).

## DISCUSSION

The complexity of the transcriptional regulatory networks in bacterial organisms is largely affected by their adaptation to the dynamically changing environmental stresses that are characteristic of an organism's niche. For example, enteric bacteria, soil bacteria and other free-living bacteria live in complex environments and have correspondingly complex sensor-response-control subsystems (46). In contrast, the narrow ecological ranges and frequent population bottlenecks of obligate pathogens and symbionts have resulted in increased rates of genetic drift and reduced selective constraint on gene function and number (47-49). Our results indicate that obligate symbiotic as well as parasitic life styles share only around 10% of the orthologous components of the TRNs of *E. coli* and *B. subtilis*. The loss of regulatory elements may reflect a relative constancy in the host environment, allowing these organisms to have a simplified regulatory structure (46,50). According to our results, the loss of transcription factors more than target genes could be the main cause of these dramatic changes in the TRN. This can also be seen from the specific scenario of the conservation of global regulators of *E. coli* which have a limited biological distribution although they directly modulate the expression of about 51% of its genes (5).

As previously reported, the conservation of genes and regulatory interactions is related to the phylogenetic distance and to the life style of the organisms (10,38). Based on our results, we can see that quantitatively that transcription factors are less conserved than the target genes as phylogenetic distance increases, which could suggest that transcriptional regulation of genes changes faster through evolution than the genes themselves. Related to this, Maslov *et al.* (51) found that the rate of evolutionary differentiation of transcriptional regulatory interactions proceeds faster than that of target genes and their protein interactions. However, an analysis of the conservation of pairs of regulatory interactions across genomes indicated different tendencies in the conservation of TF-TG pairs, suggesting that TF-TG pairs often do not co-evolve in the evolution of TRNs. Nevertheless it should be clear that in the first case, when a TF is conserved in different species without its corresponding TG, it would imply that the TF is indeed involved in the regulation of a different set of TGs than those in the genome under consideration and in the second case, when a TG is conserved and its TF is lost, it could imply that the TG is regulated by an analogous or paralogous factor. Both cases suggest a level of plasticity that TRNs can impose on the evolution of genomes to different

environments. The evolutionary reasons for the observed tendencies in the conservation of TF-TG pairs need to be analyzed more specifically.

Despite poor conservation of the regulatory interactions across genomes, certain individual interactions have been well conserved across different eubacterial phyla, which could regulate essential transcriptional processes in Bacteria. Most of these processes are well characterized and are related directly or indirectly to the translational, structural and transcriptional machinery of the cell, suggesting a cause for their conserved nature across wide phylogenetic distances. Despite the type of regulation (repressor or activator) and that DNA binding site(s) can change across genomes, it is reasonable to think that it is important to maintain the regulation of these core processes through the same elements, as in the case of BirA and DnaA regulators which seem to be a result of common ancestry in all bacteria.

The transcriptional regulatory network appears to evolve in a step-wise manner, with loss and gain of individual interactions probably playing a greater role than loss and gain of whole motifs or modules of interactions. As Teichmann and Babu (52) reported previously, most network motifs have risen by convergent evolution and not by genetic duplication of ancestral circuits. Thus, with the exception of a small fraction of the TRN, it could be possible that large portions of the TRNs might have evolved through extensive changes and re-connections among the components of the network in the evolution of the species. Here we demonstrate that individual elements, interacting pairs and groups of interactions are not conserved, in fact even in closely related species. This reflects that in each speciation event to adapt to environmental changes, transcriptional regulation is more flexible than the genetic component of the organisms for phenotypic adaptation. This work should provide a perspective of the plasticity of the transcriptional regulatory network in bacteria, which could contribute to understand the transcriptional basis of natural variation.

Supplementary material including the complete set of regulons in *Escherichia coli K12* and *Bacillus subtilis* analyzed in this work and predicted regulons in complete genomes can be downloaded from:

[http://www.ccg.unam.mx/Computational\\_Genomics/TRNS/conservation/](http://www.ccg.unam.mx/Computational_Genomics/TRNS/conservation/).

## **ACKNOWLEDGEMENTS**

We would like to thank Heladia Salgado Osorio for supplying the interaction data from RegulonDB and to Kenta Nakai and Yuko Makita for providing us the data of transcriptional regulation from DBTBS. We would also like to thank J. Javier Díaz Mejía, Gabriel Moreno-Hagelsieb, Cei Abreu Goodger and Bruno Contreras Moreira for insightful discussions and comments on the manuscript. We would also like to acknowledge support from CONACyT program number 185993.

## REFERENCES

1. Fell, D.A. and Wagner, A. (2000) The small world of metabolism. *Nat Biotechnol*, **18**, 1121-1122.
2. Thieffry, D., Huerta, A.M., Perez-Rueda, E. and Collado-Vides, J. (1998) From specific gene regulation to genomic networks: a global analysis of transcriptional regulation in *Escherichia coli*. *Bioessays*, **20**, 433-440.
3. Ouzounis, C.A. and Karp, P.D. (2000) Global properties of the metabolic map of *Escherichia coli*. *Genome Res*, **10**, 568-576.
4. Shen-Orr, S.S., Milo, R., Mangan, S. and Alon, U. (2002) Network motifs in the transcriptional regulation network of *Escherichia coli*. *Nat Genet*, **31**, 64-68.
5. Martinez-Antonio, A. and Collado-Vides, J. (2003) Identifying global regulators in transcriptional regulatory networks in bacteria. *Curr Opin Microbiol*, **6**, 482-489.
6. Erill, I., Jara, M., Salvador, N., Escribano, M., Campoy, S. and Barbe, J. (2004) Differences in LexA regulon structure among Proteobacteria through in vivo assisted comparative genomics. *Nucleic Acids Res*, **32**, 6617-6626.
7. Herrgard, M.J., Covert, M.W. and Palsson, B.O. (2004) Reconstruction of microbial transcriptional regulatory networks. *Curr Opin Biotechnol*, **15**, 70-77.
8. Mazurie, A., Bottani, S. and Vergassola, M. (2005) An evolutionary and functional assessment of regulatory network motifs. *Genome Biol*, **6**, R35.
9. Yu, H., Luscombe, N.M., Lu, H.X., Zhu, X., Xia, Y., Han, J.D., Bertin, N., Chung, S., Vidal, M. and Gerstein, M. (2004) Annotation transfer between genomes: protein-protein interologs and protein-DNA regulogs. *Genome Res*, **14**, 1107-1118.
10. Babu, M.M., Luscombe, N.M., Aravind, L., Gerstein, M. and Teichmann, S.A. (2004) Structure and evolution of transcriptional regulatory networks. *Curr Opin Struct Biol*, **14**, 283-291.
11. Yeger-Lotem, E., Sattath, S., Kashtan, N., Itzkovitz, S., Milo, R., Pinter, R.Y., Alon, U. and Margalit, H. (2004) Network motifs in integrated cellular networks of transcription-regulation and protein-protein interaction. *Proc Natl Acad Sci U S A*, **101**, 5934-5939.
12. Sharan, R., Suthram, S., Kelley, R.M., Kuhn, T., McCuine, S., Uetz, P., Sittler, T., Karp, R.M. and Ideker, T. (2005) Conserved patterns of protein interaction in multiple species. *Proc Natl Acad Sci U S A*, **102**, 1974-1979.
13. Struhl, K. (1999) Fundamentally different logic of gene regulation in eukaryotes and prokaryotes. *Cell*, **98**, 1-4.
14. Salgado, H., Gama-Castro, S., Martinez-Antonio, A., Diaz-Peredo, E., Sanchez-Solano, F., Peralta-Gil, M., Garcia-Alonso, D., Jimenez-Jacinto, V., Santos-Zavaleta, A., Bonavides-Martinez, C. et al. (2004) RegulonDB (version 4.0): transcriptional

- regulation, operon organization and growth conditions in *Escherichia coli* K-12. *Nucleic Acids Res*, **32**, D303-306.
15. Makita, Y., Nakao, M., Ogasawara, N. and Nakai, K. (2004) DBTBS: database of transcriptional regulation in *Bacillus subtilis* and its contribution to comparative genomics. *Nucleic Acids Res*, **32**, D75-77.
  16. Kanehisa, M., Goto, S., Kawashima, S., Okuno, Y. and Hattori, M. (2004) The KEGG resource for deciphering the genome. *Nucleic Acids Res*, **32**, D277-280.
  17. Teichmann, S.A., Murzin, A.G. and Chothia, C. (2001) Determination of protein function, evolution and interactions by structural genomics. *Curr Opin Struct Biol*, **11**, 354-363.
  18. Chothia, C., Gough, J., Vogel, C. and Teichmann, S.A. (2003) Evolution of the protein repertoire. *Science*, **300**, 1701-1703.
  19. Bork, P., Dandekar, T., Diaz-Lazcoz, Y., Eisenhaber, F., Huynen, M. and Yuan, Y. (1998) Predicting function: from genes to genomes and back. *J Mol Biol*, **283**, 707-725.
  20. Wilson, C.A., Kreychman, J. and Gerstein, M. (2000) Assessing annotation transfer for genomics: quantifying the relations between protein sequence, structure and function through traditional and probabilistic scores. *J Mol Biol*, **297**, 233-249.
  21. Lan, N., Montelione, G.T. and Gerstein, M. (2003) Ontologies for proteomics: towards a systematic definition of structure and function that scales to the genome level. *Curr Opin Chem Biol*, **7**, 44-54.
  22. Lopez, R., Silventoinen, V., Robinson, S., Kibria, A. and Gish, W. (2003) WU-Blast2 server at the European Bioinformatics Institute. *Nucleic Acids Res*, **31**, 3795-3798.
  23. Bateman, A., Birney, E., Durbin, R., Eddy, S.R., Howe, K.L. and Sonnhammer, E.L. (2000) The Pfam protein families database. *Nucleic Acids Res*, **28**, 263-266.
  24. Fitch, W.M. (1970) Distinguishing homologous from analogous proteins. *Syst Zool*, **19**, 99-113.
  25. Sonnhammer, E.L. and Koonin, E.V. (2002) Orthology, paralogy and proposed classification for paralog subtypes. *Trends Genet*, **18**, 619-620.
  26. Tatusov, R.L., Koonin, E.V. and Lipman, D.J. (1997) A genomic perspective on protein families. *Science*, **278**, 631-637.
  27. Huynen, M.A. and Bork, P. (1998) Measuring genome evolution. *Proc Natl Acad Sci U S A*, **95**, 5849-5856.
  28. Janga, S.C. and Moreno-Hagelsieb, G. (2004) Conservation of adjacency as evidence of paralogous operons. *Nucleic Acids Res*, **32**, 5392-5397.

29. Li, W., Jaroszewski, L. and Godzik, A. (2002) Tolerating some redundancy significantly speeds up clustering of large protein databases. *Bioinformatics*, **18**, 77-82.
30. Hegyi, H. and Gerstein, M. (2001) Annotation transfer for genomics: measuring functional divergence in multi-domain proteins. *Genome Res*, **11**, 1632-1640.
31. Bornberg-Bauer, E., Beaussart, F., Kummerfeld, S.K., Teichmann, S.A. and Weiner, J., 3rd. (2005) The evolution of domain arrangements in proteins and interaction networks. *Cell Mol Life Sci*, **62**, 435-445.
32. Wheelan, S.J., Marchler-Bauer, A. and Bryant, S.H. (2000) Domain size distributions can predict domain boundaries. *Bioinformatics*, **16**, 613-618.
33. Eddy, S.R. (1996) Hidden Markov models. *Curr Opin Struct Biol*, **6**, 361-365.
34. Brown, J.R., Douady, C.J., Italia, M.J., Marshall, W.E. and Stanhope, M.J. (2001) Universal trees based on large combined protein sequence data sets. *Nat Genet*, **28**, 281-285.
35. Yang, S., Doolittle, R.F. and Bourne, P.E. (2005) Phylogeny determined by protein domain content. *Proc Natl Acad Sci U S A*, **102**, 373-378.
36. de Hoon, M.J., Imoto, S., Nolan, J. and Miyano, S. (2004) Open source clustering software. *Bioinformatics*, **20**, 1453-1454.
37. Coulson, R.M., Enright, A.J. and Ouzounis, C.A. (2001) Transcription-associated protein families are primarily taxon-specific. *Bioinformatics*, **17**, 95-97.
38. Madan Babu, M., Teichmann, S.A. and Aravind, L. (2006) Evolutionary dynamics of prokaryotic transcriptional regulatory networks. *J Mol Biol*, **358**, 614-633.
39. Brinkman, A.B., Ettema, T.J., de Vos, W.M. and van der Oost, J. (2003) The Lrp family of transcriptional regulators. *Mol Microbiol*, **48**, 287-294.
40. Friedberg, D., Midkiff, M. and Calvo, J.M. (2001) Global versus local regulatory roles for Lrp-related proteins: *Haemophilus influenzae* as a case study. *J Bacteriol*, **183**, 4004-4011.
41. Jeong, H., Tombor, B., Albert, R., Oltvai, Z.N. and Barabasi, A.L. (2000) The large-scale organization of metabolic networks. *Nature*, **407**, 651-654.
42. Date, S.V. and Marcotte, E.M. (2003) Discovery of uncharacterized cellular systems by genome-wide analysis of functional linkages. *Nat Biotechnol*, **21**, 1055-1062.
43. Makarova, K.S., Mironov, A.A. and Gelfand, M.S. (2001) Conservation of the binding site for the arginine repressor in all bacterial lineages. *Genome Biol*, **2**, RESEARCH0013.
44. Rodionov, D.A., Mironov, A.A. and Gelfand, M.S. (2002) Conservation of the biotin regulon and the BirA regulatory signal in Eubacteria and Archaea. *Genome Res*, **12**, 1507-1516.

45. Doerks, T., Andrade, M.A., Lathe, W., 3rd, von Mering, C. and Bork, P. (2004) Global analysis of bacterial transcription factors to predict cellular target processes. *Trends Genet*, **20**, 126-131.
46. Cases, I., de Lorenzo, V. and Ouzounis, C.A. (2003) Transcription regulation and environmental adaptation in bacteria. *Trends Microbiol*, **11**, 248-253.
47. Moran, N.A. (1996) Accelerated evolution and Muller's ratchet in endosymbiotic bacteria. *Proc Natl Acad Sci U S A*, **93**, 2873-2878.
48. Itoh, T., Martin, W. and Nei, M. (2002) Acceleration of genomic evolution caused by enhanced mutation rate in endocellular symbionts. *Proc Natl Acad Sci U S A*, **99**, 12944-12948.
49. Andersson, S.G. and Kurland, C.G. (1998) Reductive evolution of resident genomes. *Trends Microbiol*, **6**, 263-268.
50. Wilcox, J.L., Dunbar, H.E., Wolfinger, R.D. and Moran, N.A. (2003) Consequences of reductive evolution for gene expression in an obligate endosymbiont. *Mol Microbiol*, **48**, 1491-1500.
51. Maslov, S., Sneppen, K., Eriksen, K.A. and Yan, K.K. (2004) Upstream plasticity and downstream robustness in evolution of molecular networks. *BMC Evol Biol*, **4**, 9.
52. Teichmann, S.A. and Babu, M.M. (2004) Gene regulatory network growth by duplication. *Nat Genet*, **36**, 492-496.

**Table 1. Statistical significance of conservation for the different categories of TF-TG pairs in the TRNs of *Escherichia coli* K12 and *Bacillus subtilis*.**

<i>Escherichia coli</i> K12			<i>Bacillus subtilis</i>		
Category	Interaction s	Z-score(P-value)	Category	Interaction s	Z-score(P-value)
TF = TG	15	<b>5.44 (&lt; 0.0001)</b>	TF = TG	15	<b>2.99 (0.0028)</b>
TF > TG	813	<b>-5.06 (&lt; 0.0001)</b>	TF > TG	363	<b>3.24 (0.0012)</b>
TF < TG	759	<b>3.68 (0.00023)</b>	TF < TG	349	<b>-3.60 (0.00032)</b>

#### FIGURE LEGENDS:


**Figure 1. Conservation of the components of the TRN (TFs and TGs) across the three domains of life for a) *Escherichia coli* K12 and b) *Bacillus subtilis*.** In X axis are 110 non-redundant genomes ordered by phylogenetic distance (see Methods). In Y-axis (to the left) is the percentage of conservation of the elements (TFs and TGs) of the TRNs. CI values (shown to the right on the Y-axis) represent a measure of conservation of the components of the TRN of a genome with respect to the conservation of its genes. Color codes on X-axis represent different phylogenetic clades as described in the supplementary material.

**Figure 2. Conservation of Global Regulators (GR) and their regulons across genomes for a) *Escherichia coli* K12 and b) *Bacillus subtilis*.** Note that for GRs only presence (in black) or absence (in white) is shown (upper section) while for regulons percentage of interactions conserved is shown (lower section for each GR). Genomes are arranged in increasing order of phylogenetic distance with respect to the organism of reference.


**Figure 3. Classification of TF-TG pairs into three different categories.** Examples of TF-TG pairs distributed in to different classes based on their co-evolution pattern: a) TFs and TGs co-evolve [*dnaA* and *dnaN* in *E. coli* where  $D_{\text{dnaA}}=3/(3+75)=0.038$  and  $D_{\text{dnaN}}=9/(9+75)=0.107$ ] b) TF is evolutionarily more conserved than TG [*fur* and *entD* in *E. coli* where  $D_{\text{fur}}=70/(70+2)=0.972$  and  $D_{\text{entD}}=0/(0+2)=0$ ] and c) TF is less conserved than TG [*metJ* and *ahpC* in *E. coli* where  $D_{\text{metJ}}=1/(1+11)=0.083$  and  $D_{\text{ahpC}}=81/(81+11)=0.88$ ].

**Figure 4. Conservation of regulons across genomes clustered by the extent of TRN and regulon conservation for a) *Escherichia coli* K12 and b) *Bacillus subtilis*.** The intensity of the color for each regulon in each genome indicates the percentage of total interactions in the regulon shared.


**Figure 1a.**




**Figure 1b.**




**Figure 2a.**



**Figure 2b.**





**Figure 3.**






Figure 4a.



**Figure 4b.**



**ANEXO 1.****(Also Supplementary material for the paper)**

Additional information for the 204 complete genomes analyzed in this work. (Sources NCBI taxonomy). Those in blue are the list of non-redundant genomes used in the analysis. Each color in column 1 describes a phylogenetic clade.

PHYLO GENETIC CLADE	SPECIES NAME	ABBREVIATION	SIZE (nts)	SIZE (genes)	IN-PARALOG PROTEINS	OXYGEN RESPONSE	LIFE STYLE	TEMPERATURE LEVELS	PATHOGEN
1 <b>GAMMA (γ) PROTEOBACTERIA</b>	<b>Escherichia coli K-12 MG1655</b>	e.coli M54	4639675	4289	51	facultative	host-associated	mesophilic	no
	Escherichia coli O157 Sakai	e.coli_o157j	5594477	5447	287	facultative	host-associated	mesophilic	yes
	Escherichia coli CFT073	e.coli_cft073	5231428	5379	116	facultative	host-associated	mesophilic	yes
	Escherichia coli O157 EDL933	e.coli_o157	5528445	5349	348	facultative	host-associated	mesophilic	yes
	Escherichia coli K-12 W3110	e.coli_j	4641433	4390	101				
	<b>Salmonella typhi CT18</b>	s.typhi	5133713	4767	80	facultative	host-associated	mesophilic	yes
	Salmonella typhimurium LT2	s.typhimurium	4951371	4553	37	facultative	host-associated	mesophilic	yes
	Salmonella enterica serovar typhi Ty2	s.typhi_ty2	4791961	4323	53	facultative	host-associated	mesophilic	yes
	<b>Photorhabdus luminescens subsp. laumondii TTO1</b>	p.luminescens	5688987	4683	190	facultative	host-associated	mesophilic	yes
	<b>Erwinia carotovora subsp. atroseptica SCRI1043</b>	e.carotovora	5064019	4472	20	facultative	multiple	mesophilic	yes
	<b>Shigella flexneri 301 (serotype 2a)</b>	s.flexneri	4828821	4180	514	facultative	host-associated	mesophilic	no
	Shigella flexneri 2457T (serotype 2a)	s.flexneri_2457t	4599354	4068	471	facultative	host-associated	mesophilic	yes
	<b>Yersinia pestis biovar Mediaevails 91001</b>	y.pestis_mediaevails	4803217	4142	168	facultative	multiple	mesophilic	yes
	Yersinia pestis KIM	y.pestis_kim	4701745	4090	158	facultative	multiple	mesophilic	yes
	Yersinia pestis CO92	y.pestis	4829855	4083	211	facultative	multiple	mesophilic	yes
	Yersinia pseudotuberculosis IP32953	y.pseudotuberculosis	4840899	4038	39	facultative	multiple	mesophilic	yes
	<b>Wigglesworthia brevipalpis</b>	w.brevipalpis	703004	611	0	facultative	host-associated	mesophilic	no
	<b>Blochmannia flordanus</b>	b.flordanus	705557	583	0	facultative	host-associated	mesophilic	yes
	<b>Buchnera aphidicola APS</b>	buchnera	655725	574	1	aerobic	host-associated	mesophilic	no
	Buchnera aphidicola Sg	b.aphidicola_sg	641454	504	0	aerobic	host-associated	mesophilic	no
	Buchnera aphidicola Bp	b.aphidicola_bp	615980	545	0	aerobic	host-associated	mesophilic	no
	<b>Mannheimia succiniciproducens MBEL55E</b>	m.succiniciproducens	2314078	2384	20	facultative	host-associated	mesophilic	no
	<b>Pasteurella multocida PM70</b>	p.multocida	2257487	2014	2	facultative	host-associated	mesophilic	yes
	<b>Haemophilus ducreyi 35000HP</b>	h.ducreyi	1698955	1717	28	anaerobic	host-associated	mesophilic	yes
	Haemophilus influenzae (serotype d)	h.influenzae	1830138	1709	10	facultative	host-associated	mesophilic	yes
	<b>Photobacterium profundum</b>	p.profundum	6403280	5413	317	anaerobic	multiple	mesophilic	yes
	<b>Vibrio vulnificus YJ016</b>	v.vulnificus_yj016	5260086	5028	69	facultative	aquatic	mesophilic	no
	Vibrio parahaemolyticus	v.parahaemolyticus	5165770	4832	29	facultative	aquatic	mesophilic	yes
	Vibrio vulnificus CMCP6	v.vulnificus	5126798	4537	88	facultative	aquatic	mesophilic	no
	Vibrio cholerae El Tor N16961	v.cholerae	4033464	3828	69	facultative	aquatic	mesophilic	yes
	<b>Pseudomonas aeruginosa PA01</b>	p.aeruginosa	6264403	5565	19	aerobic	multiple	mesophilic	no

	Pseudomonas syringae DC3000	p.syringae	6538260	5471	201	aerobic	multiple	mesophilic	yes
	Pseudomonas putida KT2440	p.putida	6181863	5350	54	aerobic	multiple	mesophilic	yes
	<b>Shewanella oneidensis MR-1</b>	s.oneidensis	5131416	4778	232	facultative	multiple	mesophilic	yes
	<b>Xanthomonas axonopodis</b>	x.axonopodis	5274174	4312	61	aerobic	host-associated	mesophilic	yes
	Xanthomonas campestris 8004	x.campestris	5148708	4181	93	aerobic	host-associated	mesophilic	yes
	<b>Acinetobacter sp. ADP1</b>	acinetobacter_adp1	3598621	3325	20	aerobic	multiple	mesophilic	
	<b>Methylococcus capsulatus</b>	m.capsulatus	3304561	2959	40				
	<b>Legionella pneumophila Philadelphia 1</b>	l.pneumophila	3397754	2942	19	aerobic	host-associated	mesophilic	yes
	<b>Xylella fastidiosa 9a5c</b>	x.fastidiosa	2731750	2831	93	aerobic	host-associated	mesophilic	yes
	Xylella fastidiosa Temecula1	x.fastidiosa_t	2521148	2036	59	aerobic	host-associated	mesophilic	yes
	<b>Coxiella burnetii RSA 493</b>	c.burnetii	2032674	2009	26	facultative	multiple	mesophilic	yes
<b>2</b>	<b>Burkholderia pseudomallei K96243</b>	b.pseudomallei	7247547	5728	58				
	Burkholderia mallei	b.mallei	5835527	4764	246				
	<b>Ralstonia solanacearum</b>	r.solanacearum	5810922	5116	131	aerobic	multiple	mesophilic	no
	<b>Bordetella bronchiseptica RB50</b>	b.bronchiseptica	5339179	4994	45	aerobic	host-associated	mesophilic	yes
	Bordetella parapertussis	b.parapertussis	4773551	4185	40	aerobic	host-associated	mesophilic	yes
	Bordetella pertussis	b.pertussis	4086189	3447	239	aerobic	host-associated	mesophilic	yes
	<b>Chromobacterium violaceum</b>	c.violaceum	4751080	4407	10	facultative	multiple	mesophilic	yes
	<b>Nitrosomonas europaea</b>	n.europaea	2812094	2461	117	aerobic	multiple	mesophilic	no
	<b>Neisseria meningitidis Z2491 (serogroup A)</b>	n.meningitidis_a	2184406	2065	51	aerobic	host-associated	mesophilic	no
	Neisseria meningitidis MC58 (serogroup B)	n.meningitidis	2272360	2025	82	aerobic	host-associated	mesophilic	no
<b>3</b>	<b>Bradyrhizobium japonicum</b>	b.japonicum	9105828	8317	104	aerobic	host-associated	mesophilic	no
	<b>Mesorhizobium loti</b>	m.loti	7596297	7281	65	aerobic	multiple	mesophilic	no
	<b>Sinorhizobium meliloti</b>	s.meliloti	6691694	6205	114	aerobic	multiple	mesophilic	yes
	<b>Agrobacterium tumefaciens C58 (UWash/Dupont)</b>	a.tumefaciens	5674064	5402	18	aerobic	multiple	mesophilic	yes
	Agrobacterium tumefaciens C58 (Cereon)	a.tumefaciens_c	5673465	5301	24	aerobic	multiple	mesophilic	yes
	<b>Rhodopseudomonas palustris CGA009</b>	r.palustris	5459213	4814	14	facultative	multiple	mesophilic	yes
	<b>Caulobacter crescentus CB15</b>	c.crescentus	4016947	3737	29	aerobic	aquatic	mesophilic	no
	<b>Brucella suis 1330</b>	b.suis	3315175	3264	19	aerobic	host-associated	mesophilic	yes
	Brucella melitensis 16M	b.melitensis	3294931	3198	19	aerobic	host-associated	mesophilic	yes
	<b>Bartonella henselae</b>	b.henselae	1931047	1488	46				
	Bartonella quintana Toulouse	b.quintana	1581384	1142	5				
	<b>Rickettsia conorii Malish 7</b>	r.conorii	1268755	1374	1	aerobic	host-associated	mesophilic	yes
	Rickettsia typhi	r.typhi	1111496	838	2				
	Rickettsia prowazekii	r.prowazekii	1111523	834	0	aerobic	host-associated	mesophilic	yes
	<b>Wolbachia wMel</b>	wolbachia_mel	1267782	1195	42				
<b>4</b>	<b>Bdellovibrio bacteriovorus HD100</b>	b.bacteriovorus	3782950	3583	0				
	<b>Desulfovibrio vulgaris Hildenborough</b>	d.vulgaris	3773159	3531	41				
	<b>Geobacter sulfurreducens</b>	g.sulfurreducens	3814139	3445	36				
	<b>Desulfotalea psychrophila</b>	d.psychrophila	3659634	3236	20				

5 <b>EPSILON PROTEOBACTERIA</b>	<b>Wolinella succinogenes DSMZ 1740</b>	w.succinogenes	2110355	2044	21	microaerophilic	host-associated	mesophilic	yes
	<b>Helicobacter hepaticus</b>	h.hepaticus	1799146	1875	3	aerobic	host-associated	mesophilic	yes
	Helicobacter pylori 26695	h.pylori	1667867	1566	18	aerobic	host-associated	mesophilic	yes
	Helicobacter pylori J99	h.pylori_j99	1643831	1491	4	aerobic	host-associated	mesophilic	yes
	<b>Campylobacter jejuni NCTC11168</b>	c.jejuni	1641481	1634	2	microaerophilic	multiple	mesophilic	yes
6 <b>THERMUS/ DEINOCOCCUS</b>	<b>Deinococcus radiodurans R1</b>	d.radiodurans	3284156	3102	32	aerobic	soil	mesophilic	no
			2127482						
7 <b>CYANOBACTERIA</b>	<b>Thermus thermophilus HB27</b>	t.thermophilus		2210	20				
	<b>Anabaena sp. PCC7120</b>	anabaena	7211789	6131	91				
	<b>Gloeobacter violaceus</b>	g.violaceus	4659019	4430	33		soil	mesophilic	no
	<b>Synechocystis sp. PCC6803</b>	synechocystis	3573470	3264	61		aquatic	mesophilic	no
	<b>Synechococcus sp. PCC6301</b>	synechococcus_pcc6301	2696255	2525	5				
	Synechococcus sp. WH8102	synechococcus_wh8102	2434428	2517	7		aquatic	mesophilic	no
	<b>Thermosynechococcus elongatus BP-1</b>	t.elongatus	2593857	2475	78		specialized	thermophilic	yes
	<b>Prochlorococcus marinus MIT9313</b>	p.marinus_mit9313	2410873	2265	9		aquatic	mesophilic	
	Prochlorococcus marinus SS120	p.marinus	1751080	1882	2		aquatic	mesophilic	
	Prochlorococcus marinus MED4	p.marinus_med4	1657990	1712	5		aquatic	mesophilic	
8 <b>CLOSTRIDIUM</b>	<b>Clostridium acetobutylicum</b>	c.acetobutylicum	4132880	3848	6	anaerobic	multiple	mesophilic	no
	Clostridium perfringens	c.perfringens	3085740	2723	5	anaerobic	multiple	mesophilic	yes
	Clostridium tetani E88	c.tetani	2873333	2373	27	anaerobic	multiple	mesophilic	yes
	<b>Thermoanaerobacter tengcongensis</b>	t.tengcongensis	2689445	2588	81	anaerobic	specialized	hyperthermophilic	no
9 <b>BACILLALES</b>	<b>Bacillus subtilis</b>	b.subtilis	4214630	4106	4	facultative	soil	mesophilic	no
	Bacillus licheniformis DSM13	b.licheniformis_dsm13	4222645	4196	20				
	Bacillus licheniformis ATCC 14580	b.licheniformis	4222334	4161	19				
	Bacillus halodurans	b.halodurans	4202352	4066	82	facultative	multiple	mesophilic	no
	Bacillus anthracis A2012	b.anthracis_a2012	5370060	5852	7	facultative	multiple	mesophilic	yes
	Bacillus anthracis Ames 0581	b.anthracis_ames0581	5503926	5558	8	facultative	soil	mesophilic	yes
	Bacillus anthracis Ames	b.anthracis	5227293	5311	8				
	Bacillus anthracis Sterne	b.anthracis_sterne	5228663	5287	7				
	Bacillus cereus ATCC 10987	b.cereus_atcc10987	5432652	5603	16	aerobic	soil	mesophilic	yes
	Bacillus cereus ATCC 14579	b.cereus	5427083	5255	27				
	Bacillus cereus ZK	b.cereus_zk	5843235	5134	6				
	Bacillus thuringiensis 97-27	b.thuringiensis	5314794	5117	41				
	<b>Oceanobacillus iheyensis HTE831</b>	o.iheyensis	3630528	3496	15	aerobic	multiple	mesophilic	yes
	<b>Listeria innocua CLIP 11262 (serotype 6a)</b>	l.innocua	3093113	3043	38	facultative	multiple	mesophilic	yes
	Listeria monocytogenes EGD-e	l.monocytogenes	2944528	2846	3	facultative	multiple	mesophilic	yes
	Listeria monocytogenes F2365	l.monocytogenes_f2365	2905310	2821	6				
	<b>Staphylococcus aureus Mu50</b>	s.aureus_mu50	2903636	2748	35	facultative	host-associated	mesophilic	yes
	Staphylococcus aureus MRSA252	s.aureus_mrsa252	2902619	2656	34				
	Staphylococcus aureus MW2	s.aureus_mw2	2820462	2632	5	facultative	host-associated	mesophilic	yes
	Staphylococcus aureus N315	s.aureus_n315	2839469	2623	38	facultative	host-associated	mesophilic	yes

10 LACTO BACILLALES	<i>Staphylococcus aureus</i> MSSA476	s.aureus_mssa476	2820454	2579	3					
	<i>Staphylococcus epidermidis</i> ATCC 12228	s.epidermidis	2564615	2419	38	facultative	host-associated	mesophilic	yes	
	<b><i>Streptococcus thermophilum</i></b>	s.thermophilum		3337	563	facultative	host-associated	mesophilic	yes	
	<i>Streptococcus agalactiae</i> 2603	s.agalactiae	2160267	2124	25	facultative	host-associated	mesophilic	yes	
	<i>Streptococcus agalactiae</i> NEM316	s.agalactiae_nem316	2211485	2094	100	facultative	host-associated	mesophilic	yes	
	<i>Streptococcus pneumoniae</i> TIGR4	s.pneumoniae	2160837	2094	35	facultative	multiple	mesophilic	yes	
	<i>Streptococcus pneumoniae</i> R6	s.pneumoniae_r6	2038615	2043	42	facultative	multiple	mesophilic	yes	
	<i>Streptococcus mutans</i>	s.mutans	2030921	1960	12	facultative	host-associated	mesophilic	yes	
	<i>Streptococcus pyogenes</i> MGAS10394 (serotype M6)	s.pyogenes_mgas10394	1899877	1886	23					
	<i>Streptococcus pyogenes</i> MGAS315 (serotype M3)	s.pyogenes_m3	1900521	1865	31	facultative	host-associated	mesophilic	yes	
	<i>Streptococcus pyogenes</i> SSI-1 (serotype M3)	s.pyogenes_ssi1	1894275	1861	26	facultative	host-associated	mesophilic	yes	
	<i>Streptococcus pyogenes</i> MGAS8232 (serotype M18)	s.pyogenes_m18	1895017	1845	28	facultative	host-associated	mesophilic	yes	
	<i>Streptococcus pyogenes</i> SF370 (serotype M1)	s.pyogenes	1852441	1696	14	facultative	host-associated	mesophilic	yes	
	<b><i>Streptococcus pyogenes</i> MGAS6180 (serotype M28)</b>	e.faecalis	1897573	3113	23	facultative	multiple	mesophilic	yes	
11 MOLLIICUTES	<b><i>Lactobacillus plantarum</i></b>	l.plantarum	3348625	3009	20	facultative	host-associated	mesophilic	no	
	<i>Lactobacillus johnsonii</i>	l.johnsonii	1992676	1821	12					
	<b><i>Lactococcus lactis</i></b>	l.lactis	2365589	2266	72	facultative	multiple	mesophilic	no	
	<b><i>Mycoplasma penetrans</i></b>	m.penetrans	1358633	1037	27	facultative	host-associated	mesophilic	yes	
	<i>Mycoplasma mycoides</i>	m.mycoides	1211703	1016	130					
	<i>Mycoplasma pulmonis</i>	m.pulmonis	963879	782	6	facultative	host-associated	mesophilic	yes	
	<i>Mycoplasma gallisepticum</i>	m.gallisepticum	996422	726	7	facultative	host-associated	mesophilic	yes	
12 CFB/ GREEN SULFUR BACTERIA	<i>Mycoplasma pneumoniae</i>	m.pneumoniae	816394	688	3	facultative	host-associated	mesophilic	no	
	<i>Mycoplasma mobile</i>	m.mobile	777079	633	4					
	<i>Mycoplasma genitalium</i>	m.genitalium	580074	480	0	facultative	host-associated	mesophilic	yes	
	<b><i>Onion yellows phytoplasma OY-M</i></b>	phytoplasma_oy	860631	754	79					
	<b><i>Mesoplasma florum</i></b>	m.florum	793224	683	0					
	<b><i>Ureaplasma urealyticum</i></b>	u.urealyticum	751719	611	2	facultative	host-associated	mesophilic	yes	
	<b><i>Bacteroides thetaiotaomicron</i></b>	b.thetaiotaomicron	6293399	4778	69	anaerobic	host-associated	mesophilic		
13 ACTINO BACTERIA	<i>Bacteroides fragilis</i> YCH46	b.fragilis	5310990	4625	24					
	<b><i>Chlorobium tepidum TLS</i></b>	c.tepidum	2154946	2252	8	anaerobic	specialized	thermophilic	no	
	<b><i>Porphyromonas gingivalis W83</i></b>	p.gingivalis	2343476	1909	71	anaerobic	host-associated	mesophilic	yes	
	<b><i>Streptomyces coelicolor</i></b>	s.coelicolor	9054847	7897	128	aerobic	multiple	mesophilic	no	
	<i>Streptomyces avermitilis</i>	s.avermtilis	9119895	7671	28	aerobic	multiple	mesophilic	no	
	<b><i>Mycobacterium avium paratuberculosis</i></b>	m.avium_paratuberculosis	4829781	4350	41					
	<i>Mycobacterium tuberculosis</i> CDC1551	m.tuberculosis_cdc1551	4403837	4187	32	aerobic	host-associated	mesophilic	yes	
	<i>Mycobacterium tuberculosis</i> H37Rv	m.tuberculosis	4411532	3869	58	aerobic	host-associated	mesophilic	yes	
	<i>Mycobacterium bovis</i>	m.bovis	4345492	3920	25	aerobic	host-associated	mesophilic	yes	

	Mycobacterium leprae	m.leprae	3268203	1605	5	aerobic	host-associated	mesophilic	yes
	<b>Corynebacterium glutamicum (Kitasato)</b>	c.glutamicum	3309401	2993	31	facultative	multiple	mesophilic	no
	Corynebacterium efficiens	c.efficiens	3147090	2950	81	facultative	multiple	mesophilic	no
	Corynebacterium diphtheriae	c.diphtheriae	2488635	2272	12	aerobic	multiple	mesophilic	yes
	<b>Propionibacterium acnes</b>	p.acnes	2560265	2297	4				
	<b>Leifsonia xyli xyli CTCB07</b>	l.xyli	2584158	2030	36				
	<b>Bifidobacterium longum</b>	b.longum	2260266	1729	8	anaerobic	host-associated	mesophilic	no
	<b>Tropheryma whipplei Twist</b>	t.whipplei	927303	808	4	aerobic	host-associated	mesophilic	yes
	Tropheryma whipplei TW08/27	t.whipplei_s	925938	783	5	aerobic	host-associated	mesophilic	yes
	<b>Leptospira interrogans serovar lai</b>	l.interrogans	4691184	4727	79	aerobic	host-associated	mesophilic	yes
	Leptospira interrogans serovar Copenhageni	l.interrogans_copenhageni	4627366	3660	32				
	<b>Treponema denticola</b>	t.denticola	2843201	2767	23				
	Treponema pallidum	t.pallidum	1138011	1031	2	anaerobic	host-associated	mesophilic	yes
	<b>Borrelia burgdorferi</b>	b.burgdorferi	1519856	1637	221	aerobic	host-associated	mesophilic	yes
	Borrelia garinii	b.garinii	986914	832	0				
	<b>Parachlamydia sp. UWE25</b>	parachlamydia_uwe25	2414465	2031	26				
	<b>Chlamydophila pneumoniae TW183</b>	c.pneumoniae_tw183	1225935	1113	0		host-associated	mesophilic	yes
	Chlamydophila pneumoniae AR39	c.pneumoniae_ar39	1229853	1110	3		host-associated	mesophilic	yes
	Chlamydophila pneumoniae J138	c.pneumoniae_j138	1226565	1069	0		host-associated	mesophilic	yes
	Chlamydophila pneumoniae CWL029	c.pneumoniae	1230230	1052	2		host-associated	mesophilic	yes
	Chlamydophila caviae	c.caviae	1181356	1005	0		host-associated	mesophilic	yes
	<b>Chlamydia muridarum</b>	c.muridarum	1080451	911	0		host-associated	mesophilic	yes
	Chlamydia trachomatis serovar D	c.trachomatis	1042519	894	0		host-associated	mesophilic	yes
	<b>Fusobacterium nucleatum</b>	f.nucleatum	2174500	2067	34	anaerobic	host-associated	mesophilic	yes
			7145576						
	<b>Rhodopirellula baltica</b>	r.baltica		7325	92				
	<b>Thermotoga maritima</b>	t.maritima	1860725	1846	9	anaerobic	specialized	hyperthermophilic	no
			1590791						
	<b>Aquifex aeolicus</b>	a.aeolicus		1553	5	aerobic	specialized	hyperthermophilic	no
	<b>Pyrococcus furiosus DSM 3638</b>	p.furiosus	1908256	2065	24	anaerobic	aquatic	hyperthermophilic	no
	Pyrococcus horikoshii OT3	p.horikoshii	1738505	2061	1	anaerobic	aquatic	hyperthermophilic	yes
	Pyrococcus abyssi GE5	p.abysii	1768562	1765	1	anaerobic	aquatic	hyperthermophilic	no
	<b>Methanosaeca acetivorans C2A</b>	m.acetivorans	5751492	4540	188	anaerobic	aquatic	mesophilic	no
	Methanosaeca mazae Goe1	m.mazae	4096345	3371	102	anaerobic	multiple	mesophilic	no
	<b>Halobacterium sp. NRC-1</b>	halobacterium	2571010	2605	192				
	<b>Methanobacterium thermoautotrophicum deltaH</b>	m.thermoautotrophicum	1751377	1869	3	anaerobic	specialized	hyperthermophilic	no
	<b>Methanococcus jannaschii DSM2661</b>	m.jannaschii	1739927	1770	6	anaerobic	aquatic	hyperthermophilic	no
	Methanococcus maripaludis S2	m.maripaludis	1661137	1722	0				
	<b>Methanopyrus kandleri AV19</b>	m.kandleri	1694969	1687	0	anaerobic	specialized	hyperthermophilic	no
	<b>Picrophilus torridus DSM 9790</b>	p.torridus	1545895	1535	0				

	<b>Archaeoglobus fulgidus VC-16</b>	a.fulgidus	2178400	2407	19	anaerobic	aquatic	hyperthermophilic	no
	<b>Thermoplasma volcanium GSS1</b>	t.volcanium	1584804	1526	9	facultative	specialized	thermophilic	no
	Thermoplasma acidophilum DSM 1728	t.acidophilum	1564906	1478	2	facultative	specialized	thermophilic	no
<b>19 CRENARCHAEOTA</b>	<b>Sulfolobus solfataricus</b>	s.solfataricus	2992245	2977	204	aerobic	specialized	hyperthermophilic	no
	Sulfolobus tokodaii	s.tokodaii	2694756	2826	53	aerobic	specialized	hyperthermophilic	no
	<b>Aeropyrum pernix K1</b>	a.pernix	1669695	2694	1	aerobic	specialized	hyperthermophilic	no
	<b>Pyrobaculum aerophilum IM2</b>	p.aerophilum	2222430	2605	17	facultative	aquatic	hyperthermophilic	no
	<b>Nanoarchaeum equitans Kin4-M</b>	n.equitans	490885	536	0	anaerobic	host-associated	hyperthermophilic	yes
	<b>Plasmodium falciparum 3D7</b>	p.falciparum	21847047	5265	40				
	<b>Dictyostelium discoideum</b>	d.discoideum		12173	489				
<b>20 PROTISTS</b>	<b>Encephalitozoon cuniculi</b>	e.cuniculi	2497519	1996	124				
	<b>Ashbya gossypii (Eremothecium gossypii)</b>	a.gossypii	8764998	4726	14				
	<b>Saccharomyces cerevisiae</b>	s.cerevisiae	12156590	5855	235				
	<b>Candida albicans</b>	c.albicans		6383	200				
<b>22 PLANTAS</b>	<b>Cyanidioschyzon merolae</b>	c.merolae		4772	96				
	<b>Arabidopsis thaliana</b>	a.thaliana	119707899	28159	1716				
<b>23 ANIMALS</b>	<b>Caenorhabditis elegans</b>	c.elegans	100283706	21357	1755				
	<b>Drosophila melanogaster</b>	d.melanogaster	118377116	16130	1848				

## ANEXO 2A.

Date sets of regulons used in the entire analysis from *Escherichia coli* from Regulon DataBase v4.0: <http://regulondb.ccg.unam.mx/index.html>

Transcription Factor Name   Genebank   Bnumber	TGs Number	Target Genes Name   Genebank   Bnumber
ada 16130150 b2213	4	accA 16128178 b0185 aidB 16132009 b4187 alkA 16130008 b2068 alkB 16130149 b2212
adiY 16131942 b4116	1	adiA 16131943 b4117
alpA 16130542 b2624	1	slp 16131378 b3506
alsR 16131915 b4089	5	alsA 16131913 b4087 alsB 16131914 b4088 alsC 16131912 b4086 alsE 16131911 b4085 alsI 16131916 b4090
appY 16128547 b0564	9	appA 16128946 b0980 appB 16128945 b0979 appC 16128944 b0978 hyaA 16128938 b0972 hyaB 16128939 b0973 hyaC 16128940 b0974 hyaD 16128941 b0975 hyaE 16128942 b0976 hyaF 16128943 b0977
araC 16128058 b0064	9	araA 16128056 b0062 araB 16128057 b0063 araD 16128055 b0061 araE 16130745 b2841 araF 16129851 b1901 araG 16129850 b1900 araH_1 b1899 b1899 araH_2 b1898 b1898 araJ 16128381 b0396
arcA 16132218 b4401	88	aceA 16131841 b4015 aceB 16131840 b4014 aceK 16131842 b4016 acnA 16129237 b1276 acnB 16128111 b0118 alda 16129376 b1415 b0725 16128700 b0725 betA 16128296 b0311 betB 16128297 b0312 betI 16128298 b0313 betT 16128299 b0314 cadA 16131957 b4131 cadB 16131958 b4132 caiA 16128033 b0039 caiB 16128032 b0038 caiC 16128031 b0037 caiD 16128030 b0036 caiE 16128029 b0035 caiT 16128034 b0040 cydA 16128708 b0733 cydB 16128709 b0734 cyoA 16128417 b0432 cyoB 16128416 b0431 cyoC 16128415 b0430 cyoD 16128414 b0429 cyoE 16128413 b0428 dctA 16131400 b3528 fadA 16131691 b3845 fadB 16131692 b3846 focA 16128871 b0904 fumA 16129570 b1612 fumC 16129569 b1611 glcA 16130875 b2975 glcB 16130876 b2976 glcD 16130879 b2979 glcE 16130878 b2978 glcG 16130877 b2977 glpA 16130176 b2241 glpB 16130177 b2242 glpC 16130178 b2243 gltA 16128695 b0720 hemA 16129173 b1210 hyaA 16128938 b0972 hyaB 16128939 b0973 hyaC 16128940 b0974 hyaD 16128941 b0975 hyaE 16128942 b0976 hyaF 16128943 b0977 hyb0 16130897 b2997 hybA 16130896 b2996 hybB 16130895 b2995 hybC 16130894 b2994 hybD 16130893 b2993 hybE 16130892 b2992 hybF 16130891 b2991 hybG 16130890 b2990 icdA 16129099 b1136 lctD 16131476 b3605 lctP 16131474 b3603 lctR 16131475 b3604 lpdA 16128109 b0116 mdh 16131126 b3236 moeA 16128795 b0827 moeB 16128794 b0826 ndh 16129072 b1109 nuoA 16130223 b2288 nuoB 16130222 b2287 nuoC 16130221 b2286 nuoE 16130220 b2285 nuoF 16130219 b2284 nuoG 16130218 b2283 nuoH 16130217 b2282 nuoI 16130216 b2281 nuoJ 16130215 b2280 nuoK 16130214 b2279 nuoL 16130213 b2278 nuoM 16130212 b2277 nuoN 16130211 b2276 pf1B 16128870 b0903 sdhA 16128698 b0723 sdhB 16128699 b0724 sdhC 16128696 b0721 sdhD 16128697 b0722 sodA 16131748 b3908 sucA 16128701 b0726 sucB 16128702 b0727 sucC 16128703 b0728 sucD 16128704 b0729
argR 16131127 b3237	14	argB 16131797 b3959 argC 16131796 b3958 argD 16131238 b3359 argE 16131795 b3957 argF 16128258 b0273 argH 16131798 b3960 argI 16132076 b4254 astA 16129701 b1747 astB 16129699 b1745 astC 16129702 b1748 astD 16129700 b1746 astE 16129698 b1744 carA 16128026 b0032 carB 16128027 b0033
asnC 16131611 b3743	1	asnA 16131612 b3744
atoC 16130157 b2220	3	atoA 16130159 b2222 atoD 16130158 b2221 atoE 16130160 b2223
betI 16128298 b0313	3	betA 16128296 b0311 betB 16128297 b0312 betT 16128299 b0314
birA 16131807 b3973	5	bioA 16128742 b0774 bioB 16128743 b0775 bioC 16128745 b0777 bioD 16128746 b0778 bioF 16128744 b0776
cadC 16131959 b4133	2	cadA 16131957 b4131 cadB 16131958 b4132
caif 16128028 b0034	9	caia 16128033 b0039 caib 16128032 b0038 caic 16128031 b0037 caid 16128030 b0036 caie 16128029 b0035 cait 16128034 b0040 fixB 16128036 b0042 fixC 16128037 b0043 fixX 16128038 b0044
cbl 16129929 b1987	4	tauA 16128350 b0365 tauB 16128351 b0366 tauC 16128352 b0367 tauD 16128353 b0368
cpxR 16131752 b3912	10	csgA 16129005 b1042 csgB 16129004 b1041 csgD 16129003 b1040 csgE 16129002 b1039 csgF 16129001 b1038 csgG 16129000 b1037

		dsbA 16131701 b3860 ecfI 16131556 b3688 ppiA 16131242 b3363 yihE 16131700 b3859
crp 16131236 b3357	240	acnA 16129237 b1276 acnB 16128111 b0118 acs 16131895 b4069 aldA 16129376 b1415 aldB 16131459 b3588 ansB 16130858 b2957 araA 16128056 b0062 araB 16128057 b0063 araC 16128058 b0064 araD 16128055 b0061 araE 16130745 b2841 araF 16129851 b1901 araG 16129850 b1900 araH_1 b1899 b1899 araH_2 b1898 b1898 araJ 16128381 b0396 aspA 16131964 b4139 b0725 16128700 b0725 bglG 16131591 b3723 caiA 16128033 b0039 caiB 16128032 b0038 caiC 16128031 b0037 caiD 16128030 b0036 caiE 16128029 b0035 caiF 16128028 b0034 caiT 16128034 b0040 cirA 16130093 b2155 cpdB 16132035 b4213 crr 16130343 b2417 csiD 16130573 b2659 csiE 16130460 b2535 cyaA 16131658 b3806 dadA 16129152 b1189 dadX 16129153 b1190 dctA 16131400 b3528 dcuA 16131963 b4138 dcuB 16131949 b4123 deoA 16132199 b4382 deoB 16132200 b4383 deoC 16132198 b4381 deoD 16132201 b4384 dsdA 16130298 b2366 dsdX 16130297 b2365 dusB 16131148 b3260 ebgA 16130971 b3076 ebgC 16130972 b3077 envZ 16131281 b3404 epd 16130828 b2927 fadL 16130277 b2344 fis 16131149 b3261 fixB 16128036 b0042 fixC 16128037 b0043 fixX 16128038 b0044 flhC 16129843 b1891 flhD 16129844 b1892 focA 16128871 b0904 fucA 16130707 b2800 fucI 16130709 b2802 fucK 16130710 b2803 fucO 16130706 b2799 fucP 16130708 b2801 fucR 16130712 b2805 fucU 16130711 b2804 fumB 16131948 b4122 fur 16128659 b0683 gadA 16131389 b3517 gadX 16131388 b3516 galE 16128727 b0759 galK 16128725 b0757 galM 16128724 b0756 galS 16130089 b2151 galT 16128726 b0758 gcd 16128117 b0124 glgA 16131303 b3429 glgC 16131304 b3430 glgP 16131302 b3428 glgS 16130945 b3049 glnA 16131710 b3870 glnG 16131708 b3868 glnL 16131709 b3869 glpA 16130176 b2241 glpB 16130177 b2242 glpC 16130178 b2243 glpD 16131300 b3426 glpE 16131299 b3425 glpF 16131765 b3927 glpG 16131298 b3424 glpK 16131764 b3926 glpQ 16130174 b2239 glpR 16131297 b3423 glpT 16130175 b2240 gltA 16128695 b0720 gntK 16131309 b3437 gntT 16131291 b3415 gntU_1 b3436 gntU_2 b3435 b3435 guaA 16130432 b2507 guaB 16130433 b2508 gutM 16130613 b2706 gutQ 16130615 b2708 gyrA 16130166 b2231 hlyE 16129145 b1182 hupA 16131830 b4000 hupB 16128425 b0440 idnD 16132089 b4267 idnO 16132088 b4266 idnR 16132086 b4264 idnT 16132087 b4265 ilvB 16131541 b3671 ilvN 16131540 b3670 ivbL 16131542 b3672 lacA 16128327 b0342 lacY 16128328 b0343 lacZ 16128329 b0344 lamB 16131862 b4036 lpdA 16128109 b0116 lyxK 16131451 b3580 malE 16131860 b4034 malF 16131859 b4033 malG 16131858 b4032 malI 16129578 b1620 malK 16131861 b4035 malM 16131863 b4037 malP 16131293 b3417 malQ 16131292 b3416 mals 16131442 b3571 malT 16131294 b3418 malX 16129579 b1621 malY 16129580 b1622 manX 16129771 b1817 manY 16129772 b1818 manZ 16129773 b1819 mdh 16131126 b3236 melA 16131945 b4119 melB 16131946 b4120 melR 16131944 b4118 mglA 16130087 b2149 mglB 16130088 b2150 mglC 16130086 b2148 mhpA 16128332 b0347 mhpB 16128333 b0348 mhpC 16128334 b0349 mhpD 16128335 b0350 mhpE 16128337 b0352 mhpF 16128336 b0351 mp1 16132055 b4233 mtlA 16131470 b3599 mtlD 16131471 b3600 mtlR 16131472 b3601 nagA 16128653 b0677 nagB 16128654 b0678 nagC 16128652 b0676 nagD 16128651 b0675 nagE 16128655 b0679 nmpC 16128536 b0553 nupC 16130325 b2393 nupG 16130865 b2964 ompA 16128924 b0957 ompR 16131282 b3405 osmY 16132194 b4376 oxyR 16131799 b3961 paaA 16129349 b1388 paaB 16129350 b1389 paaC 16129351 b1390 paaD 16129352 b1391 paaE 16129353 b1392 paaF 16129354 b1393 paaG 16129355 b1394 paaH 16129356 b1395 paaI 16129357 b1396 paaJ 16129358 b1397 paaK 16129359 b1398 paaZ 16129348 b1387 pf1B 16128870 b0903 pgk 16130827 b2926 ppiA 16131242 b3363 proP 16131937 b4111 ptsG 16129064 b1101 ptsH 16130341 b2415 ptsI 16130342 b2416 putP 16128981 b1015 rbsA 16131617 b3749 rbsB 16131619 b3751 rbsC 16131618 b3750 rbsD 16131616 b3748 rbsK 16131620 b3752 rhaA 16131743 b3903 rhaB 16131744 b3904 rhaD 16131742 b3902 rhaR 16131746 b3906 rhaS 16131745 b3905 rhaT 16131747 b3907 rpoH 16131333 b3461 rpoS 16130648 b2741 sdhA 16128698 b0723 sdhB 16128699 b0724 sdhC 16128696 b0721 sdhD 16128697 b0722 serA 16130814 b2913 sgbE 16131454 b3583 sgbH 16131452 b3581 sgbU 16131453 b3582 sohB 16129233 b1272 speC 16130866 b2965 srlA 16130609 b2702 srlB 16130611 b2704 srlD 16130612 b2705 srlE 16130610 b2703 srlR 16130614 b2707 sucA 16128701 b0726 sucB 16128702 b0727 sucC 16128703 b0728 sucD 16128704 b0729 tdcA 16131011 b3118 tdcB 16131010 b3117 tdcC 16131009 b3116 tdcD 16131008 b3115 tdcE 16131007 b3114 tdcF 16131006 b3113 tdcG 16131005 b3112 tnaA 16131576 b3708 tnaB 16131577 b3709 tnaL 16131575 b3707 treB 16132062 b4240 treC 16132061 b4239 tsx 16128396 b0411 ubiG 16130167 b2232 udp 16131680 b3831 uhpT 16131536 b3666 uxuA 16132143 b4322 uxuB 16132144 b4323 yhfA 16131235 b3356 yiaJ 16131445 b3574 yiaK 16131446 b3575 yiaL 16131447 b3576 yiaM 16131448 b3577 yiaN 16131449 b3578 yiaO 16131450 b3579 yjcG 16131893 b4067 yjcH 16131894 b4068
csgD 16129003 b1040	5	csgA 16129005 b1042 csgB 16129004 b1041 csgE 16129002 b1039 csgF 16129001 b1038 csgG 16129000 b1037
cspA 16131427 b3556	2	gyrA 16130166 b2231 hns 16129198 b1237
cspE 16128606 b0623	1	cspA 16131427 b3556
cusR 16128554 b0571	4	cusA 16128558 b0575 cusB 16128557 b0574 cusC 16128555 b0572 cusF 16128556 b0573
cynR 16128323 b0338	3	cynS 16128325 b0340 cynT 16128324 b0339 cynX 16128326 b0341

<b>cysB 16129236 b1275</b>	17	cb1 16129929 b1987 cysA 16130348 b2422 cysC 16130657 b2750 cysD 16130659 b2752 cysH 16130669 b2762 cysI 16130670 b2763 cysJ 16130671 b2764 cysK 16130340 b2414 cysM 16130347 b2421 cysN 16130658 b2751 cysP 16130350 b2425 cysU 16130349 b2424 cysW b2423 b2423 tauA 16128350 b0365 tauB 16128351 b0366 tauC 16128352 b0367 tauD 16128353 b0368
<b>cytR 16131772 b3934</b>	10	deoA 16132199 b4382 deoB 16132200 b4383 deoC 16132198 b4381 deoD 16132201 b4384 nupC 16130325 b2393 nupG 16130865 b2964 ppiA 16131242 b3363 rpoH 16131333 b3461 tsx 16128396 b0411 udp 16131680 b3831
<b>dcuR 16131950 b4124</b>	7	dctA 16131400 b3528 dcuB 16131949 b4123 frdA 16131979 b4154 frdB 16131978 b4153 frdC 16131977 b4152 frdD 16131976 b4151 fumB 16131948 b4122
<b>deoR 16128808 b0840</b>	6	deoA 16132199 b4382 deoB 16132200 b4383 deoC 16132198 b4381 deoD 16132201 b4384 nupG 16130865 b2964 tsx 16128396 b0411
<b>dnaA 16131570 b3702</b>	8	aldA 16129376 b1415 dnaN 16131569 b3701 guaA 16130432 b2507 guaB 16130433 b2508 nrdA 16130169 b2234 nrdB 16130170 b2235 recF 16131568 b3700 rpoH 16131333 b3461
<b>dsdC 16130296 b2364</b>	2	dsdA 16130298 b2366 dsdX 16130297 b2365
<b>ebgR 16130970 b3075</b>	2	ebgA 16130971 b3076 ebgC 16130972 b3077
<b>emrR 16130596 b2684</b>	2	emrA 16130597 b2685 emrB 16130598 b2686
<b>envY 16128549 b0566</b>	2	ompC 16130152 b2215 ompF 16128896 b0929
<b>exuR 16130989 b3094</b>	1	exuT 16130988 b3093
<b>fadR 16129150 b1187</b>	7	fabA 16128921 b0954 fadA 16131691 b3845 fadB 16131692 b3846 fadD 16129759 b1805 fadL 16130277 b2344 iclR 16131844 b4018 uspA 16131367 b3495
<b>fhlA 16130638 b2731</b>	26	fdhF 16131905 b4079 hycA 16130632 b2725 hycB 16130631 b2724 hycC 16130630 b2723 hycD 16130629 b2722 hycE 16130628 b2721 hycF 16130627 b2720 hycG 16130626 b2719 hycH 16130625 b2718 hydN 16130620 b2713 hyfA 16130 b2481 hyfB 16130407 b2482 hyfC 16130408 b2483 hyfD 16130409 b2484 hyfE 16130410 b2485 hyfF 16130411 b2486 hyfG 16130412 b2487 hyfH 16130413 b2488 hyfI 16130414 b2489 hyfJ 16130415 b2490 hypA 16130633 b2726 hypB 16130634 b2727 hypC 16130635 b2728 hypD 16130636 b2729 hypE 16130637 b2730 hypF 16130619 b2712
<b>fis 16131149 b3261</b>	76	acnB 16128111 b0118 acs 16131895 b4069 adhE 16129202 b1241 alaT b3853 b3853 alaW b2397 b2397 aldB 16131459 b3588 argX b3796 b3796 bg1G 16131591 b3723 cysG 16131246 b3368 dusB 16131148 b3260 guaA 16130432 b2507 guaB 16130433 b2508 gyrA 16130166 b2231 gyrB 16131567 b3699 hns 16129198 b1237 hupA 16131830 b4000 hupB 16128425 b0440 infB 16131060 b3168 leuP b4369 b4369 leuX b4270 b4270 lpdA 16128109 b0116 marA 16129490 b1531 marB 16129491 b1532 marR 16129489 b1530 mazE 16130690 b2783 mazF 16130689 b2782 metT b0673 b0673 mtlA 16131470 b3599 mtlD 16131471 b3600 mtlR 16131472 b3601 ndh 16129072 b1109 nirB 16131244 b3365 nirC b3367 b3367 nirD 16131245 b3366 nrdA 16130169 b2234 nrdB 16130170 b2235 nrfA 16131896 b4070 nrfB 16131897 b4071 nrfC 16131898 b4072 nrfD 16131899 b4073 nrfE 16131900 b4074 nrfF 16131901 b4075 nrfG 16131902 b4076 nuoA 16130223 b2288 nuoB 16130222 b2287 nuoC 16130221 b2286 nuoE 16130220 b2285 nuoF 16130219 b2284 nuoG 16130218 b2283 nuoH 16130217 b2282 nuoI 16130216 b2281 nuoJ 16130215 b2280 nuoK 16130214 b2279 nuoL 16130213 b2278 nuoM 16130212 b2277 nuoN 16130211 b2276 nusA 16131061 b3169 pheU b4134 b4134 pnp 16131056 b3164 proL b2189 b2189 proM b3799 b3799 rbfa 16131059 b3167 rpsO 16131057 b3165 serT b0971 b0971 sra 16129439 b1480 thrT b3979 b3979 thrV b3273 b3273 thrW b0244 b0244 tpr 16129192 b1229 trmA 16131803 b3965 trub 16131058 b3166 tyrT b1231 b1231 tyrU b3977 b3977 yhbC 16131062 b3170 yjcG 16131893 b4067 yjcH 16131894 b4068
<b>flihD 16129844 b1892</b>	26	fliA 16129869 b1922 fliL 16129891 b1944 fliM 16129892 b1945 fliN 16129893 b1946 fliO 16129894 b1947 fliP 16129895 b1948 fliQ 16129896 b1949 fliR 16129897 b1950 fliY 16129867 b1920 fliZ 16129868 b1921 glpA 16130176 b2241 glpB 16130177 b2242 glpC 16130178 b2243 hydN 16130620 b2713 hypF 16130619 b2712 mdh 16131126 b3236 mglA 16130087 b2149 mglB 16130088 b2150 mglC 16130086 b2148 nrfA 16131896 b4070 nrfB 16131897 b4071 nrfC 16131898 b4072 nrfD 16131899 b4073 nrfE 16131900 b4074 nrfF 16131901 b4075 nrfG 16131902 b4076
<b>fnr 16129295 b1334</b>	112	acna 16129237 b1276 adhE 16129202 b1241 ansB 16130858 b2957 arcA 16132218 b4401 aspA 16131964 b4139 b0725 16128700 b0725 caiF 16128028 b0034 ccmA 16130138 b2201 ccmB 16130137 b2200 ccmC 16130136 b2199 ccmD 16130135 b2198 ccmE 16130134 b2197 ccmF 16130133 b2196 ccmH 16130131 b2194 cydA 16128708 b0733 cydB 16128709 b0734 cydC 16128853 b0886 cydD 16128854 b0887 cyoA 16128417 b0432 cyoB 16128416 b0431 cyoC 16128415 b0430 cyoD 16128414 b0429 cyoE 16128413 b0428 cysG 16131246 b3368 dcuA 16131963 b4138 dcuB 16131949 b4123 dmsA 16128861 b0894 dmsB 16128862 b0895 dmsC 16128863 b0896 dsbE 16130132 b2195 fdnH 16129434 b1475 fdnI 16129435 b1476 focA 16128871 b0904 frdA 16131979 b4154 frdB 16131978 b4153 frdC 16131977 b4152

		frdD 16131976 b4151 fumB 16131948 b4122 glpA 16130176 b2241 glpB 16130177 b2242 glpC 16130178 b2243 hemA 16129173 b1210 hlyE 16129145 b1182 hypA 16130633 b2726 hypB 16130634 b2727 hypC 16130635 b2728 hypD 16130636 b2729 hypE 16130637 b2730 icdA 16129099 b1136 moaA 16128749 b0781 moaB 16128750 b0782 moaC 16128751 b0783 moaD 16128752 b0784 moaE 16128753 b0785 moeA 16128795 b0827 moeB 16128794 b0826 napA 16130143 b2206 napB 16130140 b2203 napC 16130139 b2202 napD 16130144 b2207 napF 16130145 b2208 napG 16130142 b2205 napH 16130141 b2204 narG 16129187 b1224 narH 16129188 b1225 narI 16129190 b1227 narJ 16129189 b1226 narK 16129186 b1223 narL 16129184 b1221 narX 16129185 b1222 ndh 16129072 b1109 nikA 16131348 b3476 nikB 16131349 b3477 nikC 16131350 b3478 nikD 16131351 b3479 nikE 16131352 b3480 nikR 16131353 b3481 nirB 16131244 b3365 nirC b3367 b3367 nirD 16131245 b3366 nrfA 16131896 b4070 nrfB 16131897 b4071 nrfC 16131898 b4072 nrfD 16131899 b4073 nrfE 16131900 b4074 nrfF 16131901 b4075 nrfG 16131902 b4076 nuoA 16130223 b2288 nuoB 16130222 b2287 nuoC 16130221 b2286 nuoE 16130220 b2285 nuoF 16130219 b2284 nuoG 16130218 b2283 nuoH 16130217 b2282 nuoI 16130216 b2281 nuoJ 16130215 b2280 nuoK 16130214 b2279 nuoL 16130213 b2278 nuoM 16130212 b2277 nuoN 16130211 b2276 pf1B 16128870 b0903 sdhA 16128698 b0723 sdhB 16128699 b0724 sdhC 16128696 b0721 sdhD 16128697 b0722 sodA 16131748 b3908 sucA 16128701 b0726 sucB 16128702 b0727 sucC 16128703 b0728 sucD 16128704 b0729 yeiL 16130101 b2163 yfiD 16130504 b2579
<b>fruR 16128073 b0080</b>	25	aceA 16131841 b4015 aceB 16131840 b4014 aceK 16131842 b4016 adhE 16129202 b1241 crr 16130343 b2417 cysG 16131246 b3368 eda 16129803 b1850 edd 16129804 b1851 epd 16130828 b2927 fruA 16130105 b2167 fruB 16130107 b2169 fruK 16130106 b2168 icdA 16129099 b1136 mtlA 16131470 b3599 mtlD 16131471 b3600 mtlR 16131472 b3601 nirB 16131244 b3365 nirC b3367 b3367 nirD 16131245 b3366 pckA 16131280 b3403 pgk 16130827 b2926 ppsA 16129658 b1702 ptsH 16130341 b2415 ptsI 16130342 b2416 pykF 16129632 b1676
<b>fucR 16130712 b2805</b>	6	fucA 16130707 b2800 fucI 16130709 b2802 fucK 16130710 b2803 fuco 16130706 b2799 fucP 16130708 b2801 fucU 16130711 b2804
<b>fur 16128659 b0683</b>	33	cirA 16130093 b2155 entA 16128579 b0596 entB 16128578 b0595 entC 16128576 b0593 entD 16128566 b0583 entE 16128577 b0594 entS 16128574 b0591 exbB 16130904 b3006 exbD 16130903 b3005 fecA 16132112 b4291 fecB 16132111 b4290 fecC 16132110 b4289 fecD 16132109 b4288 fecE 16132108 b4287 fecI 16132114 b4293 fecR 16132113 b4292 fepA 16128567 b0584 fepB 16128575 b0592 fepC 16128571 b0588 fepD 16128573 b0590 fepG 16128572 b0589 fhuA 16128143 b0150 fhuB 16128146 b0153 fhuC 16128144 b0151 fhuD 16128145 b0152 fhuE 16129065 b1102 nrdE 16130589 b2675 nrdF 16130590 b2676 nrdH 16130587 b2673 nrdI 16130588 b2674 sodA 16131748 b3908 tonB 16129213 b1252 ybdB 16128580 b0597
<b>gadW 16131387 b3515</b>	2	gadA 16131389 b3517 gadX 16131388 b3516
<b>gadX 16131388 b3516</b>	1	gadA 16131389 b3517
<b>galR 16130741 b2837</b>	5	gale 16128727 b0759 galK 16128725 b0757 galM 16128724 b0756 gals 16130089 b2151 galT 16128726 b0758
<b>gals 16130089 b2151</b>	3	mglA 16130087 b2149 mglB 16130088 b2150 mglC 16130086 b2148
		gatA 16130032 b2094 gatB 16130031 b2093 gatC 16130030 b2092 gatD 16130029 b2091 gatR_2 b2090 b2090 gatY 16130034 b2096 gatZ 16130033 b2095
<b>gcvA 16130715 b2808</b>	3	gcvH 16130806 b2904 gcvP 16130805 b2903 gcvT 16130807 b2905
<b>gcvR 16130404 b2479</b>	3	gcvH 16130806 b2904 gcvP 16130805 b2903 gcvT 16130807 b2905
<b>glcC 16130880 b2980</b>	5	glcA 16130875 b2975 glcB 16130876 b2976 glcD 16130879 b2979 glcE 16130878 b2978 glcG 16130877 b2977
<b>glnL 16131709 b3869</b>	34	amtB 16128436 b0451 argT 16130245 b2310 astA 16129701 b1747 astB 16129699 b1745 astC 16129702 b1748 astD 16129700 b1746 astE 16129698 b1744 cbl 16129929 b1987 ddpA 16129446 b1487 ddpB 16129445 b1486 ddpC 16129444 b1485 ddpD 16129443 b1484 ddpF 16129442 b1483 ddpX 16129447 b1488 glnA 16131710 b3870 glnG 16131708 b3868 glnH 16128779 b0811 glnK 16128435 b0450 glnP 16128778 b0810 glnQ 16128777 b0809 hisJ 16130244 b2309 hisM 16130242 b2307 hisP 16130241 b2306 hisQ 16130243 b2308 nac 16129930 b1988 potF 16128822 b0854 potG 16128823 b0855 potH 16128824 b0856 potI 16128825 b0857 ycdG 16128972 b1006 yhdW 16131156 b3268 yhdX 16131157 b3269 yhdY 16131158 b3270 yhdZ 16131159 b3271
<b>glpR 16131297 b3423</b>	8	glpA 16130176 b2241 glpB 16130177 b2242 glpC 16130178 b2243 glpD 16131300 b3426 glpF 16131765 b3927 glpK 16131764 b3926 glpQ 16130174 b2239 glpT 16130175 b2240
<b>gntR 16131310 b3438</b>	6	eda 16129803 b1850 edd 16129804 b1851 gntK 16131309 b3437 gntT 16131291 b3415 gntU_1 b3436 b3436 gntU_2 b3435 b3435
<b>gutM 16130613 b2706</b>	6	gutQ 16130615 b2708 srlA 16130609 b2702 srlB 16130611 b2704 srlD 16130612 b2705 srlE 16130610 b2703 srlR 16130614 b2707
<b>himA 16129668 b1712</b>	160	aceA 16131841 b4015 aceB 16131840 b4014 aceK 16131842 b4016 acs 16131895 b4069 adiA 16131943 b4117 amiA 16130360 b2435 caiA 16128033 b0039 caiB 16128032 b0038 caiC 16128031 b0037 caiD 16128030 b0036 caiE 16128029 b0035 caiT 16128034 b0040

		carA 16128026 b0032 carB 16128027 b0033 cysG 16131246 b3368 dmsA 16128861 b0894 dmsB 16128862 b0895 dmsC 16128863 b0896 dppA 16131416 b3544 dppB 16131415 b3543 dppC 16131414 b3542 dppD 16131413 b3541 dppF 16131412 b3540 dps 16128780 b0812 dusB 16131148 b3260 ecpD 16128133 b0140 envZ 16131281 b3404 fimA 16132135 b4314 fimC 16132137 b4316 fimD 16132138 b4317 fimF 16132139 b4318 fimG 16132140 b4319 fimH 16132141 b4320 fimI 16132136 b4315 fis 16131149 b3261 flhC 16129843 b1891 flhD 16129844 b1892 focA 16128871 b0904 gcd 16128117 b0124 glcA 16130875 b2975 glcB 16130876 b2976 glcD 16130879 b2979 glcE 16130878 b2978 glcG 16130877 b2977 glnH 16128779 b0811 glnP 16128778 b0810 glnQ 16128777 b0809 gltA 16128695 b0720 hemA 16129173 b1210 hemF 16130361 b2436 himD 16128879 b0912 htrE 16128132 b0139 hycA 16130632 b2725 hycB 16130631 b2724 hycC 16130630 b2723 hycD 16130629 b2722 hycE 16130628 b2721 hycF 16130627 b2720 hycG 16130626 b2719 hycH 16130625 b2718 hypA 16130633 b2726 hypB 16130634 b2727 hypC 16130635 b2728 hypD 16130636 b2729 hypE 16130637 b2730 ilvA 16131630 b3772 ilvD 16131629 b3771 ilvE 16131628 b3770 ilvG_1 b3767 b3767 ilvG_2 b3768 b3768 ilvL 16131626 b3766 ilvM 16131627 b3769 lyxK 16131451 b3580 mtr 16131053 b3161 narG 16129187 b1224 narH 16129188 b1225 narI 16129190 b1227 narJ 16129189 b1226 narK 16129186 b1223 ndh 16129072 b1109 nirB 16131244 b3365 nirC b3367 b3367 nirD 16131245 b3366 nmpC 16128536 b0553 nrfA 16131896 b4070 nrfB 16131897 b4071 nrfC 16131898 b4072 nrfD 16131899 b4073 nrfE 16131900 b4074 nrfF 16131901 b4075 nrfG 16131902 b4076 nuoA 16130223 b2288 nuoB 16130222 b2287 nuoC 16130221 b2286 nuoE 16130220 b2285 nuoF 16130219 b2284 nuoG 16130218 b2283 nuoH 16130217 b2282 nuoI 16130216 b2281 nuoJ 16130215 b2280 nuoK 16130214 b2279 nuoL 16130213 b2278 nuoM 16130212 b2277 nuoN 16130211 b2276 ompC 16130152 b2215 ompF 16128896 b0929 ompR 16131282 b3405 osmE 16129693 b1739 osmY 16132194 b4376 paaA 16129349 b1388 paaB 16129350 b1389 paaC 16129351 b1390 paaD 16129352 b1391 paaE 16129353 b1392 paaF 16129354 b1393 paaG 16129355 b1394 paaH 16129356 b1395 paaI 16129357 b1396 paaJ 16129358 b1397 paaK 16129359 b1398 paaZ 16129348 b1387 pf1B 16128870 b0903 phoU 16131592 b3724 pspA 16129265 b1304 pspB 16129266 b1305 pspC 16129267 b1306 pspD 16129268 b1307 pspE 16129269 b1308 pstA 16131594 b3726 pstB 16131593 b3725 pstC 16131595 b3727 pstS 16131596 b3728 rtcA b3420 b3420 rtcB 16131295 b3421 sgbE 16131454 b3583 sgbH 16131452 b3581 sgbU 16131453 b3582 sodA 16131748 b3908 sodB 16129614 b1656 sucA 16128701 b0726 sucB 16128702 b0727 sucC 16128703 b0728 sucD 16128704 b0729 tdcA 16131011 b3118 tdcB 16131010 b3117 tdcC 16131009 b3116 tdcD 16131008 b3115 tdcE 16131007 b3114 tdcF 16131006 b3113 tdcG 16131005 b3112 tyrP 16129857 b1907 yeiL 16130101 b2163 yiaJ 16131445 b3574 yiaK 16131446 b3575 yiaL 16131447 b3576 yiaM 16131448 b3577 yiaN 16131449 b3578 yiaO 16131450 b3579 yjcG 16131893 b4067 yjcH 16131894 b4068
hns 16129198 b1237	33	adiA 16131943 b4117 bglG 16131591 b3723 bolA 16128420 b0435 cadA 16131957 b4131 cadB 16131958 b4132 csid 16130573 b2659 csiE 16130460 b2535 cydA 16128708 b0733 cydB 16128709 b0734 cysG 16131246 b3368 chiA 16131217 b3338 flhC 16129843 b1891 flhD 16129844 b1892 fliA 16129869 b1922 fliY 16129867 b1920 fliz 16129868 b1921 gadA 16131389 b3517 gadX 16131388 b3516 hlyE 16129145 b1182 mukB 16128891 b0924 mukE 16128890 b0923 mukF 16128889 b0922 nhaA 16128013 b0019 nirB 16131244 b3365 nirC b3367 b3367 nirD 16131245 b3366 proV 16130591 b2677 proW 16130592 b2678 proX 16130593 b2679 rcsA 16129898 b1951 smtA 16128888 b0921 sodB 16129614 b1656 stpA 16130583 b2669
hupA 16131830 b4000	5	gale 16128727 b0759 galK 16128725 b0757 galM 16128724 b0756 galT 16128726 b0758 seqA 16128663 b0687
hyfR 16130416 b2491	10	hyfA 16130 b2481 hyfB 16130407 b2482 hyfC 16130408 b2483 hyfD 16130409 b2484 hyfE 16130410 b2485 hyfF 16130411 b2486 hyfG 16130412 b2487 hyfH 16130413 b2488 hyfI 16130414 b2489 hyfJ 16130415 b2490
iciA 16130817 b2916	5	dnaA 16131570 b3702 dnaN 16131569 b3701 nrdA 16130169 b2234 nrdB 16130170 b2235 recF 16131568 b3700
iclR 16131844 b4018	3	aceA 16131841 b4015 aceB 16131840 b4014 aceK 16131842 b4016
ilvY 16131631 b3773	1	ilvC 16131632 b3774
iscR 16130456 b2531	3	iscA 16130453 b2528 iscS 16130455 b2530 iscU 16130454 b2529
kdpE 16128670 b0694	3	kdpA 16128674 b0698 kdpB 16128673 b0697 kdpC 16128672 b0696
lacI 16128330 b0345	3	lacA 16128327 b0342 lacY 16128328 b0343 lacZ 16128329 b0344
lctR 16131475 b3604	2	lctD 16131476 b3605 lctP 16131474 b3603
leuO 16128070 b0076	5	leuA 16128068 b0074 leuB 16128067 b0073 leuC 16128066 b0072 leuD 16128065 b0071 leuL 16128069 b0075
lexA 16131869 b4043	13	dinF 16131870 b4044 dnaG 16130962 b3066 oraA 16130605 b2698 phrB 16128683 b0708 recA 16130606 b2699 rpoD 16130963 b3067 rpsU 16130961 b3065 sulA 16128925 b0958 umuC 16129147 b1184 umuD 16129146 b1183 uvrA 16131884 b4058 uvrB 16128747 b0779 uvrD 16131665 b3813
lrhA 16130224 b2289	2	flhC 16129843 b1891 flhD 16129844 b1892

		aidB 16132009 b4187 csiD 16130573 b2659 dadA 16129152 b1189 dadX 16129153 b1190 fimA 16132135 b4314 fimC 16132137 b4316 fimD 16132138 b4317 fimF 16132139 b4318 fimG 16132140 b4319 fimH 16132141 b4320 fimI 16132136 b4315 gcvH 16130806 b2904 gcvP 16130805 b2903 gcvT 16130807 b2905 gltB 16131102 b3212 gltD 16131103 b3213 gltF 16131104 b3214 ilvA 16131630 b3772 ilvD 16131629 b3771 ilvE 16131628 b3770 ilvG_1 b3767 b3767 ilvG_2 b3768 b3768 ilvH 16128071 b0078 ilvI b0077 b0077 ilvL 16131626 b3766 ilvM 16131627 b3769 kb1 16131488 b3617 leuA 16128068 b0074 leuB 16128067 b0073 leuC 16128066 b0072 leuD 16128065 b0071 leuL 16128069 b0075 livF 16131326 b3454 livG 16131327 b3455 livH 16131329 b3457 livJ 16131332 b3460 livK 16131330 b3458 livM 16131328 b3456 lysU 16131955 b4129 maltT 16131294 b3418 ompC 16130152 b2215 ompF 16128896 b0929 oppA 16129204 b1243 oppB 16129205 b1244 oppC 16129206 b1245 oppD 16129207 b1246 oppF 16129208 b1247 osmC 16129441 b1482 osmY 16132194 b4376 sdaA 16129768 b1814 serA 16130814 b2913 serC 16128874 b0907 stpA 16130583 b2669 tdh 16131487 b3616 yeiL 16130101 b2163
lyS 16130743 b2839	1	lysA 16130742 b2838
malI 16129578 b1620	2	malX 16129579 b1621 malY 16129580 b1622
malT 16131294 b3418	9	lamB 16131862 b4036 malE 16131860 b4034 malF 16131859 b4033 malG 16131858 b4032 malK 16131861 b4035 malM 16131863 b4037 malP 16131293 b3417 malQ 16131292 b3416 mals 16131442 b3571
marA 16129490 b1531	14	acrA 16128447 b0463 acrB 16128446 b0462 fpr 16131762 b3924 fumC 16129569 b1611 inaA 16130172 b2237 marB 16129491 b1532 marR 16129489 b1530 nfo 16130097 b2159 pqiA 16128917 b0950 pqiB 16128918 b0951 putA 16128980 b1014 slp 16131378 b3506 sodA 16131748 b3908 zwf 16129805 b1852
marR 16129489 b1530	2	marA 16129490 b1531 marB 16129491 b1532
melR 16131944 b4118	2	melA 16131945 b4119 melB 16131946 b4120
metJ 16131776 b3938	10	ahpC 16128588 b0605 ahpF 16128589 b0606 metA 16131839 b4013 metB 16131777 b3939 metC 16130906 b3008 metF 16131779 b3941 metI 16128191 b0198 metL 16131778 b3940 metN 16128192 b0199 metQ 16128190 b0197
metR 16131677 b3828	3	glyA 16130476 b2551 metA 16131839 b4013 metH 16131845 b4019
mhpR 16128331 b0346	6	mhpA 16128332 b0347 mhpB 16128333 b0348 mhpC 16128334 b0349 mhpD 16128335 b0350 mhpE 16128337 b0352 mhpF 16128336 b0351
mlc 16129552 b1594	8	crr 16130343 b2417 malT 16131294 b3418 manX 16129771 b1817 manY 16129772 b1818 manZ 16129773 b1819 ptsG 16129064 b1101 ptsH 16130341 b2415 ptsI 16130342 b2416
mngR 16128705 b0730	2	mngA 16128706 b0731 mngB 16128707 b0732
modE 16128729 b0761	36	ccmA 16130138 b2201 ccmB 16130137 b2200 ccmC 16130136 b2199 ccmD 16130135 b2197 ccmF 16130133 b2196 ccmH 16130131 b2194 dmsA 16128861 b0894 dmsB 16128862 b0895 dmsC 16128863 b0896 dsbE 16130132 b2195 hycA 16130632 b2725 hycB 16130631 b2724 hycC 16130630 b2723 hycD 16130629 b2722 hycE 16130628 b2721 hycF 16130627 b2720 hycG 16130626 b2719 hycH 16130625 b2718 moaA 16128749 b0781 moaB 16128750 b0782 moaC 16128751 b0783 moaD 16128752 b0784 moaE 16128753 b0785 modA 16128731 b0763 modB 16128732 b0764 modC 16128733 b0765 napA 16130143 b2206 napB 16130140 b2203 napC 16130139 b2202 napD 16130144 b2207 napF 16130145 b2208 napG 16130142 b2205 napH 16130141 b2204 narL 16129184 b1221 narX 16129185 b1222
mtlR 16131472 b3601	2	mtlA 16131470 b3599 mtlD 16131471 b3600
nac 16129930 b1988	10	asnC 16131611 b3743 codA 16128322 b0337 codB 16128321 b0336 gabD 16130575 b2661 gabP 16130577 b2663 gabT 16130576 b2662 gltB 16131102 b3212 gltD 16131103 b3213 gltF 16131104 b3214 nupC 16130325 b2393
nadR 16132207 b4390	2	nadB 16130499 b2574 pncB 16128898 b0931
nagC 16128652 b0676	9	glmS 16131597 b3729 glmU 16131598 b3730 manX 16129771 b1817 manY 16129772 b1818 manZ 16129773 b1819 nagA 16128653 b0677 nagB 16128654 b0678 nagD 16128651 b0675 nagE 16128655 b0679
narL 16129184 b1221	80	adhE 16129202 b1241 caiF 16128028 b0034 ccmA 16130138 b2201 ccmB 16130137 b2200 ccmC 16130136 b2199 ccmD 16130135 b2198 ccmE 16130134 b2197 ccmF 16130133 b2196 ccmH 16130131 b2194 cydC 16128853 b0886 cydD 16128854 b0887 cysG 16131246 b3368 dcuB 16131949 b4123 dmsA 16128861 b0894 dmsB 16128862 b0895 dmsC 16128863 b0896 dsbE 16130132 b2195 fdnH 16129434 b1475 fdnI 16129435 b1476 focA 16128871 b0904 frdA 16131979 b4154 frdB 16131978 b4153 frdC 16131977 b4152 frdD 16131976 b4151 fumB 16131948 b4122 hyaA 16128938 b0972 hyaB 16128939 b0973 hyaC 16128940 b0974 hyaD 16128941 b0975 hyaE 16128942 b0976 hyaF 16128943 b0977 hyb0 16130897 b2997 hybA 16130896 b2996 hybB 16130895 b2995 hybC 16130894 b2994 hybD 16130893 b2993 hybE 16130892 b2992 hybF 16130891 b2991 hybG 16130890 b2990 moeA 16128795 b0827 moeB 16128794 b0826 napA 16130143 b2206 napB 16130140 b2203 napC 16130139 b2202 napD 16130144 b2207 napF 16130145 b2208 napG 16130142 b2205 napH 16130141 b2204

		narG 16129187 b1224 narH 16129188 b1225 narI 16129190 b1227 narJ 16129189 b1226 narK 16129186 b1223 nirB 16131244 b3365 nirC b3367 b3367 nirD 16131245 b3366 nrfA 16131896 b4070 nrfB 16131897 b4071 nrfC 16131898 b4072 nrfD 16131899 b4073 nrfE 16131900 b4074 nrfF 16131901 b4075 nrfG 16131902 b4076 nuoA 16130223 b2288 nuoB 16130222 b2287 nuoC 16130221 b2286 nuoE 16130220 b2285 nuoF 16130219 b2284 nuoG 16130218 b2283 nuoH 16130217 b2282 nuoI 16130216 b2281 nuoJ 16130215 b2280 nuoK 16130214 b2279 nuoL 16130213 b2278 nuoM 16130212 b2277 nuoN 16130211 b2276 pf1B 16128870 b0903 torA 16128963 b0997 torC 16128962 b0996 torD 16128964 b0998
<b>narP 16130130 b2193</b>	<b>21</b>	ccmA 16130138 b2201 ccmB 16130137 b2200 ccmC 16130136 b2199 ccmD 16130135 b2198 ccmE 16130134 b2197 ccmF 16130133 b2196 ccmH 16130131 b2194 dsbE 16130132 b2195 hyaA 16128938 b0972 hyaB 16128939 b0973 hyaC 16128940 b0974 hyaD 16128941 b0975 hyaE 16128942 b0976 hyaF 16128943 b0977 napA 16130143 b2206 napB 16130140 b2203 napC 16130139 b2202 napD 16130144 b2207 napF 16130145 b2208 napG 16130142 b2205 napH 16130141 b2204
<b>nhaR 16128014 b0020</b>	<b>2</b>	nhaA 16128013 b0019 osmC 16129441 b1482
<b>norR 16130616 b2709</b>	<b>2</b>	norV 16130617 b2710 norW 16130618 b2711
<b>ompR 16131282 b3405</b>	<b>12</b>	bolA 16128420 b0435 csgD 16129003 b1040 csgE 16129002 b1039 csgF 16129001 b1038 csgG 16129000 b1037 fadL 16130277 b2344 flhC 16129843 b1891 flhD 16129844 b1892 nmpC 16128536 b0553 ompC 16130152 b2215 ompF 16128896 b0929 sra 16129439 b1480
<b>oxyR 16131799 b3961</b>	<b>12</b>	agn43 16129941 b2000 ahpC 16128588 b0605 ahpF 16128589 b0606 dps 16128780 b0812 fur 16128659 b0683 katG 16131780 b3942 sufA 16129640 b1684 sufB 16129639 b1683 sufC 16129638 b1682 sufD 16129637 b1681 sufE 16129635 b1679 sufS 16129636 b1680
<b>paaX 16129360 b1399</b>	<b>12</b>	paaA 16129349 b1388 paaB 16129350 b1389 paaC 16129351 b1390 paaD 16129352 b1391 paaE 16129353 b1392 paaF 16129354 b1393 paaG 16129355 b1394 paaH 16129356 b1395 paaI 16129357 b1396 paaJ 16129358 b1397 paaK 16129359 b1398 paaZ 16129348 b1387
<b>pdhR 16128106 b0113</b>	<b>6</b>	aceE 16128107 b0114 aceF 16128108 b0115 lctD 16131476 b3605 lctP 16131474 b3603 lctR 16131475 b3604 lpdA 16128109 b0116
<b>phoB 16128384 b0399</b>	<b>25</b>	b4103 16131929 b4103 phnC 16131932 b4106 phnD 16131931 b4105 phnE 16131930 b4104 phnF 16131928 b4102 phnG 16131927 b4101 phnH 16131926 b4100 phnI 16131925 b4099 phnJ 16131924 b4098 phnK 16131923 b4097 phnL 16131922 b4096 phnM 16131921 b4095 phnN 16131920 b4094 phnO 16131919 b4093 phnP 16131918 b4092 phoA 16128368 b0383 phoE 16128227 b0241 phoH 16128984 b1020 phoR 16128385 b0400 phoU 16131592 b3724 psiF 16128369 b0384 pstA 16131594 b3726 pstB 16131593 b3725 pstC 16131595 b3727 pstS 16131596 b3728
<b>phoP 16129093 b1130</b>	<b>2</b>	phoQ 16129092 b1129 treR 16132063 b4241
<b>pspF 16129 b1303</b>	<b>5</b>	pspA 16129265 b1304 pspB 16129266 b1305 pspC 16129267 b1306 pspD 16129268 b1307 pspE 16129269 b1308
<b>purR 16129616 b1658</b>	<b>27</b>	codA 16128322 b0337 codB 16128321 b0336 cvpA 16130248 b2313 gcvH 16130806 b2904 gcvP 16130805 b2903 gcvT 16130807 b2905 glnB 16130478 b2553 glyA 16130476 b2551 guaA 16130432 b2507 guaB 16130433 b2508 prsA 16129170 b1207 purB 16129094 b1131 purC 16130401 b2476 purD 16131835 b4005 purE 16128507 b0523 purF 16130247 b2312 purH 16131836 b4006 purK 16128506 b0522 purL 16130482 b2557 purM 16130424 b2499 purN 16130425 b2500 pyrC 16129025 b1062 pyrD 16128912 b0945 speA 16130839 b2938 speB 16130838 b2937 ubiX 16130246 b2311 ycfC 16129095 b1132
<b>rbsR 16131621 b3753</b>	<b>5</b>	rbsA 16131617 b3749 rbsB 16131619 b3751 rbsC 16131618 b3750 rbsD 16131616 b3748 rbsK 16131620 b3752
<b>rcsB 16130154 b2217</b>	<b>9</b>	b2060 16130000 b2060 ftsA 16128087 b0094 ftsZ 16128088 b0095 osmC 16129441 b1482 rcsA 16129898 b1951 wcaA 16129999 b2059 wcaB 16129998 b2058 wza 16130002 b2062 wzB 16130001 b2061
<b>rhaR 16131746 b3906</b>	<b>1</b>	rhaS 16131745 b3905
<b>rhaS 16131745 b3905</b>	<b>4</b>	rhaA 16131743 b3903 rhaB 16131744 b3904 rhaD 16131742 b3902 rhaT 16131747 b3907
<b>rob 16132213 b4396</b>	<b>8</b>	fumC 16129569 b1611 inaA 16130172 b2237 marA 16129490 b1531 marB 16129491 b1532 marR 16129489 b1530 nfo 16130097 b2159 sodA 16131748 b3908 zwf 16129805 b1852
<b>rtcR 16131296 b3422</b>	<b>2</b>	rtcA b3420 b3420 rtcB 16131295 b3421
<b>sdiA 16129863 b1916</b>	<b>3</b>	ftsA 16128087 b0094 ftsQ 16128086 b0093 ftsZ 16128088 b0095
<b>slyA 16129600 b1642</b>	<b>1</b>	hlyE 16129145 b1182
<b>soxR 16131889 b4063</b>	<b>1</b>	soxS 16131888 b4062
<b>soxs 16131888 b4062</b>	<b>20</b>	acrA 16128447 b0463 acrB 16128446 b0462 fldA 16128660 b0684 fldB 16130797 b2895 fpr 16131762 b3924 fumC 16129569 b1611 fur 16128659 b0683 inaA 16130172 b2237 marA 16129490 b1531 marB 16129491 b1532 marR 16129489 b1530 mdaA 16128819 b0851 nfo 16130097 b2159

		pqiA 16128917 b0950 pqiB 16128918 b0951 rimK 16128820 b0852 sodA 16131748 b3908 ybjC 16128818 b0850 ybjN 16128821 b0853 zwf 16129805 b1852
<b>srlR 16130614 b2707</b>	<b>6</b>	gutM 16130613 b2706 gutQ 16130615 b2708 srlA 16130609 b2702 srlB 16130611 b2704 srlD 16130612 b2705 srlE 16130610 b2703
<b>tdcA 16131011 b3118</b>	<b>6</b>	tdcB 16131010 b3117 tdcC 16131009 b3116 tdcD 16131008 b3115 tdcE 16131007 b3114 tdcF 16131006 b3113 tdcG 16131005 b3112
<b>tdcR 16131012 b3119</b>	<b>7</b>	tdcA 16131011 b3118 tdcB 16131010 b3117 tdcC 16131009 b3116 tdcD 16131008 b3115 tdcE 16131007 b3114 tdcF 16131006 b3113 tdcG 16131005 b3112
<b>torR 16128961 b0995</b>	<b>3</b>	torA 16128963 b0997 torC 16128962 b0996 torD 16128964 b0998
<b>treR 16132063 b4241</b>	<b>2</b>	treB 16132062 b4240 treC 16132061 b4239
<b>trpR 16132210 b4393</b>	<b>11</b>	aroH 16129660 b1704 aroL 16128373 b0388 aroM 16128375 b0390 mtr 16131053 b3161 trpA 16129221 b1260 trpB 16129222 b1261 trpC 16129223 b1262 trpD 16129224 b1263 trpE 16129225 b1264 trpL 16129226 b1265 yaiA 16128374 b0389
<b>tyrR 16129284 b1323</b>	<b>10</b>	aroF 16130522 b2601 aroG 16128722 b0754 aroL 16128373 b0388 aroM 16128375 b0390 aroP 16128105 b0112 mtr 16131053 b3161 tyrA 16130521 b2600 tyrB 16131880 b4054 tyrP 16129857 b1907 yaiA 16128374 b0389
<b>uhpA 16131539 b3669</b>	<b>1</b>	uhpT 16131536 b3666
<b>xapR 16130331 b2405</b>	<b>2</b>	xapA 16130333 b2407 xapB 16130332 b2406
<b>xylR 16131440 b3569</b>	<b>5</b>	xylA 16131436 b3565 xylB 16131435 b3564 xylF 16131437 b3566 xylG 16131438 b3567 xylH 16131439 b3568
<b>yiaJ 16131445 b3574</b>	<b>9</b>	lyxK 16131451 b3580 sgbE 16131454 b3583 sgbH 16131452 b3581 sgbU 16131453 b3582 yiaK 16131446 b3575 yiaL 16131447 b3576 yiaM 16131448 b3577 yiaN 16131449 b3578 yiaO 16131450 b3579
<b>yijC 16131801 b3963</b>	<b>1</b>	fabA 16128921 b0954
<b>zraR 16131834 b4004</b>	<b>2</b>	zraP 16131832 b4002 zraS 16131833 b4003

## ANEXO 2B.

Date sets of regulons used in the entire analysis from *Bacillus subtilis* from DBTBS v4.0: <http://dbtbs.hgc.jp/>

Transcription Factor Name   Genebank   BGnumber	TGs Number	Target Genes Name   Genebank   BGnumber
abrB   16077105   BG10100	72	albA   16080789   BG12471 albB   16080790   BG12470 albC   16080791   BG12469 albD   16080792   BG12468 albE   16080793   BG12467 albF   16080794   BG12466 albG   16080795   BG12465 aprE   16078094   BG10190 argB   16078186   BG10193 argC   16078184   BG10191 argD   16078187   BG10194 argF   16078190   BG10197 argJ   16078185   BG10192 asnH   16081043   BG11116 carA   16078188   BG10195 carB   16078616   BG10196 citB   16078863   BG10478 comK   16078106   BG11059 dppA   16078357   BG10842 dppB   16078358   BG10843 dppC   16078359   BG10844 dppD   16078360   BG10845 dppE   16078361   BG10846 ftsA   16078592   BG10231 ftsZ   16078593   BG10232 hpr   16078063   BG10659 hutG   16080989   BG11099 hutH   16080986   BG10667 hutI   16080988   BG11100 hutM   16080990   BG11101 hutP   16080985   BG10666 hutU   16080987   BG10668 kapB   16080198   BG10746 kinB   16080197   BG10745 pbpE   16080497   BG10390 racX   16080496   BG10391 rbsA   16080647   BG10879 rbsB   16080649   BG10881 rbsC   16080648   BG10880 rbsD   16080646   BG10878 rbsK   16080645   BG10877 rbsR   16080644   BG10876 rok   16078488   BG13307 swo   16080788   BG12671 swoX   50812300   BG14182 sigH   16077166   BG10159 sigW   16077241   BG11573 sinI   16079516   BG10753 sinR   16079517   BG10754 spoOE   16078428   BG10769 spoVG   16077117   BG10112 ybbM   16077242   BG11574 ycnK   16077464   BG12047 yknW   16078498   BG13243 yknX   16078499   BG13244 yknY   16078500   BG13245 yknZ   16078501   BG13246 yoaW   16078938   BG13493 yocH   16078981   BG13521 yrhi   16079771   BG12298 yrhJ   16079770   BG12299 yvlA   16080566   BG14116 yvlB   16080565   BG14117 yvlC   16080564   BG14118 yvlD   16080563   BG14119 yvqH   16080365   BG14137 yxAM   16081044   BG11115 yxbA   16081041   BG11351 yxbB   16081033   BG11352 yxbC   16081039   BG11353 yxbd   16081038   BG11354 yxnB   16081042   BG14166
acoR   16077877   BG11790	4	acoA   16077873   BG12558 acoB   16077874   BG12559 acoC   16077875   BG12560 acoL   16077876   BG12561
adaA   16077249   BG10166	2	adaB   16077250   BG10167 alkaA   16077248   BG10165
ahrC   16079481   BG10309	7	argC   16078184   BG10191 rocA   16080830   BG10622 rocB   16080829   BG10623 rocC   16080828   BG10624 rocD   16081086   BG10722 rocE   16081085   BG10933 rocF   16081084   BG10932
alsR   16080655   BG10470	4	alsD   16080653   BG10472 alsS   16080654   BG10471 lctP   16077375   BG12001 ldh   16077374   BG19003
ansR   16079416   BG10299	2	ansA   16079415   BG10300 ansB   16079414   BG10301
araR   16080450   BG11913	12	abfA   16079924   BG11900 abnA   16079933   BG11901 araa   16079932   BG11904 araB   16079931   BG11905 araD   16079930   BG11906 araE   16080449   BG11907 araL   16079929   BG11908 araM   16079928   BG11909 araN   16079927   BG11910 araP   16079926   BG11911 araQ   16079925   BG11912 xsa   16079903   BG11985
arsR   16079634   BG11301	3	arsB   16079632   BG11303 arsC   16079631   BG11304 yqcK   16079633   BG11302
azlB   16079725   BG11914	4	azlC   16079724   BG11915 azlD   16079723   BG11916 brnQ   16079722   BG11918 yrdK   16079721   BG12286
birA   16079301   BG11206	7	bioA   16080075   BG11524 bioB   16080072   BG11525 bioD   16080073   BG11526 bioF   16080074   BG11527 bioI   16080071   BG11528 bioW   50812281   BG11529 ytbQ   16080070   BG11787
bkdR   16079466   BG11721	7	bcd   16079464   BG11723 bkdA1   16079461   BG10307 bkdA2   16079460   BG10306 bkdB   16079459   BG10305 buk   16079463   BG11724 lpd   16079462   BG11725 ptb   16079465   BG11722
bltR   16079711   BG10904	2	blt   16079712   BG10905 bltD   16079713   BG10906
bmrR   50812267   BG10304	1	bmr   16079457   BG10303
ccpA   16080026   BG10376	97	ackA   16079999   BG10813 acoA   16077873   BG12558 acor   16077877   BG11790 acsA   16080020   BG10370 acuA   16080021   BG10369 acuB   16080022   BG10368 acuC   16080023   BG10367 alsS   16080654   BG10471 amyE   16077373   BG10473 araa   16079932   BG11904 araB   16079931   BG11905 araE   16080449   BG11907 bglH   50812306   BG10935 bglP   16080978   BG10934 bglS   16080958   BG10476 ccpC   16078478   BG13297 citC   16079965   BG10856 citM   16078996   BG10273 citZ   16079966   BG10855 dctP   16077514   BG12075 dctR   16077513   BG12074 dctS   16077512   BG12073 deoR   16080994   BG10982 dra   16080993   BG10983 exuR   16078302   BG13211 exuT   16078301   BG13210 fbaB   16081018   BG11125 galK   16080871   BG10581 galT   16080870   BG10582 glpF   16077993   BG10186 glpK   16077994   BG10187 gntK   16081058   BG10649 gntP   16081059   BG10650 gntR   16081057   BG10648 gntZ   16081060   BG10651 hutP   16080985   BG10666 idh   16081021   BG10669 iolB   16081026   BG11118 iolC   16081025   BG11119 iolD   16081024   BG11120 iole   16081023   BG11121 iolF   16081022   BG11122

		iolH 16081020 BG11123 iolI 16081019 BG11124 kdgA 16079268 BG11396 lcfA 16079908 BG11946 levD 16079761 BG10316 leveE 16079760 BG10317 levF 16079759 BG10318 levG 16079758 BG10319 licA 16080908 BG11349 licB 16080910 BG11347 licC 16080909 BG11348 licH 16080907 BG11350 licT 16080959 BG10474 malA 16077885 BG11839 malP 16077887 BG11848 mdh 16079964 BG11386 mmgA 16079473 BG11319 mmgB 16079472 BG11320 mmgC 16079471 BG11321 mmgD 16079470 BG11322 mmgE 16079469 BG11323 mmsA 16081027 BG11117 mssM 16080932 BG11954 nupC 16080992 BG10984 pdp 50812307 BG10985 pta 16080818 BG10634 rbsR 16080644 BG10876 sacc 16079757 BG10320 scoA 16080950 BG11153 scoB 16078463 BG11154 treA 16077848 BG11010 treP 16077847 BG11009 treR 16077849 BG11011 uxAA 16078304 BG13213 uxAB 16078303 BG13212 uxAC 16078295 BG13204 uxUA 16078299 BG13208 xylA 16078823 BG10806 xylB 16078824 BG10807 xynB 16078821 BG11987 xynP 16078820 BG12262 ydhO 16077650 BG12192 yfiA 16077886 BG11847 yf1N 16077829 BG12949 yjmB 16078296 BG13205 yjmC 16078297 BG13206 yjmD 16078298 BG13207 yjmF 16078300 BG13209 yobO 16078963 BG13507 yqiQ 16079468 BG11720 yxiE 16080976 BG11134 yxjC 50812305 BG11152 yxjF 16080948 BG11155 yxkF 16080933 BG12543 yxkJ 16080928 BG12546
ccpB 16081139 BG10045	2	gntR 16081057 BG10648 xylA 16078823 BG10806
ccpC 16078478 BG13297	2	citB 16078863 BG10478 citZ 16079966 BG10855
cggR 16080448 BG14085	1	gapA 16080447 BG10827
citR 16078008 BG10853	1	citA 16078009 BG10854
citT 16077826 BG12577	1	citM 16078996 BG10273
cody 16078680 BG10968	29	acsA 16080020 BG10370 citB 16078863 BG10478 comK 16078106 BG11059 comS 16077419 BG11045 dppA 16078357 BG10842 gabP 16077698 BG11328 hag 16080589 BG10655 hutP 16080985 BG10666 ilvA 16079236 BG10673 ilvB 16079883 BG10670 ilvC 16079881 BG10672 ilvD 16079246 BG11532 ilvN 16079882 BG10671 leuA 16079880 BG11948 leuB 16079879 BG10675 leuC 16079879 BG11949 leuD 16079877 BG11950 phrC 16077446 BG11959 ptb 16079465 BG11722 rapC 16077445 BG11966 srfAA 16077417 BG10168 srfAB 16077418 BG10169 srfAC 16077420 BG10170 srfAD 16077421 BG10171 ureA 16080719 BG11981 ureB 16080718 BG11982 ureC 16080717 BG11983 ybgE 16077308 BG12749 ypmP 16079235 BG11621
comA 16080219 BG10381	10	comFA 16080600 BG10395 comFB 16080599 BG10396 comFC 16080598 BG10397 degQ 16080223 BG10378 phrA 16078309 BG10653 phrE 16079637 BG11521 rapA 16078308 BG10652 rapC 16077445 BG11966 rapE 16079636 BG11299 srfAA 16077417 BG10168
comK 16078106 BG11059	47	addA 16078127 BG10466 addB 16078126 BG10465 comC 16079859 BG10323 comEA 16079613 BG10480 comEB 16079612 BG10481 comEC 16079611 BG10482 comFA 16080600 BG10395 comGA 16079529 BG10483 comGB 16079528 BG10484 comGC 16079527 BG10485 comGD 16079526 BG10486 comGE 16079525 BG10487 comGF 16079524 BG10488 comGG 16079523 BG10489 cspB 16077975 BG10824 degR 16079253 BG10699 flgK 16080594 BG10401 flgL 16080593 BG11936 flgM 16080596 BG10399 gidA 16081153 BG10059 gidB 16081152 BG10058 glcR 16080683 BG12503 nin 16077411 BG10839 nucA 50812179 BG10838 radC 16079856 BG10325 rapH 16077751 BG11031 recA 16078757 BG10721 rok 16078488 BG13307 rpsF 16081143 BG10049 rpsR 50812313 BG10047 sbcD 50812209 BG10467 smf 16078674 BG11006 ssb 16078513 BG10048 thdF 16081154 BG10060 ybdK 16077270 BG12724 yhcH 16077973 BG11586 yhjB 16078109 BG13069 yneA 16078849 BG11820 yneB 16078850 BG11821 ynzC 16078851 BG13466 yqzE 16079522 BG13771 yvrP 16080382 BG14152 yvyF 16080597 BG10398 yvyG 16080595 BG10400 ywpH 16080684 BG12502 yyaa 16081151 BG10057 yyaF 16081144 BG10050
cssR 16080354 BG14131	3	cssS 16080355 BG14132 htrA 16078355 BG12608 yvtA 50812291 BG14155
ctsR 16077151 BG10145	11	clpC 16077154 BG10148 clpE 16078434 BG12578 clpP 16080507 BG19016 clpX 16079874 BG11387 lonA 16079872 BG10338 mcsA 16077152 BG10146 mcsB 16077153 BG10147 sms 16077155 BG10149 trxA 16079902 BG10348 yacK 16077156 BG10150 ysxc 16079871 BG10339
degU 16080602 BG10393	19	aprE 16078094 BG10190 comC 16079859 BG10323 comEA 16079613 BG10480 comFA 16080600 BG10395 comGA 16079529 BG10483 comK 16078106 BG11059 degQ 16080223 BG10378 degR 16079253 BG10699 mecA 16078217 BG10680 sacB 16080498 BG10388 sacX 16080892 BG10560 sacY 16080893 BG10559 srfAA 16077417 BG10168 wapA 16080974 BG10797 yveA 16080500 BG12429 yveB 16080499 BG12430 yxjI 16080945 BG12539 yxjJ 16080944 BG12540 yxxG 16080973 BG10798
deoR 16080994 BG10982	1	dra 16080993 BG10983
dnaA 16077069 BG10065	2	dnaN 16077070 BG10066 sda 50812270 BG14183
exuR 16078302 BG13211	1	uxaC 16078295 BG13204
fnr 16080784 BG11343	8	hemZ 16081159 BG12999 narG 16080781 BG11081 narH 16080780 BG11082 nari 16080778 BG11084 narJ 16080779 BG11083 narK 16080785 BG11342 ywcJ 16080857 BG10594 ywiD 16080782 BG11345
fruR 16078502 BG12589	2	fruA 16078504 BG11938 fruK 16078503 BG12588
fur 16079409 BG11766	34	dhbA 16080253 BG11019 dhbB 16080250 BG11241 dhbc 16080252 BG11242 dhbE 16080251 BG11020 dhbF 50812288 BG11243 feuA 16077231 BG10835

		feuB 16077230 BG10836 feuC 16077229 BG10837 fhuD 16080386 BG10828 nasE 16077398 BG11097 ybbA 16077228 BG11565 ybbB 16077232 BG10834 yclN 16077448 BG12034 yclO 16077449 BG12035 yclP 16077450 BG12036 yclQ 16077451 BG12037 ydbN 16077520 BG12081 ydhU 16077656 BG12198 yfhA 16077913 BG12876 yfhC 16077915 BG12878 yfiz 16077912 BG12902 yfkM 16077852 BG12929 yfmC 16077819 BG12954 yhfQ 16078097 BG13061 ykuN 16078479 BG13298 ykuO 16078480 BG13299 ykuP 16078481 BG13300 yoaJ 16078923 BG13481 ypbR 16079261 BG11604 yuiI 16080254 BG13974 yusV 16080346 BG14034 ywbL 16080879 BG10573 ywjA 16080776 BG11306 yxeB 16081012 BG11878
gabR 16077457 BG12042	2	gabD 16077459 BG12044 gabT 16077458 BG12043
gerE 16079893 BG10355	20	cgeA 16079036 BG11193 cgeB 16079037 BG11194 cgeC 16079035 BG11195 cgeD 16079034 BG11196 cgeE 16079033 BG11197 cota 16077697 BG10490 cotB 16080658 BG10491 cotD 16079278 BG10493 cotV 16078243 BG10496 cotW 16078242 BG10497 cotX 16078241 BG10500 cotY 16078240 BG10498 cotZ 16078239 BG10499 cwlH 16079624 BG11633 ftsY 16078658 BG11539 spoIIIC 16079692 BG10919 spoIVCB 16079629 BG10459 sspG 50812290 BG14173 yoaN 16078927 BG13484 yurS 16080317 BG14005
glcT 16078452 BG12593	3	ptsG 16078453 BG10198 ptsH 16078454 BG10200 ptsI 50812224 BG10201
glnR 16078808 BG10424	8	glnA 16078809 BG10425 nasA 16077402 BG11093 nasB 16077401 BG11094 nasC 16077400 BG11095 nasD 16077399 BG11096 nasE 16077398 BG11097 nasF 16077397 BG11098 ureA 16080719 BG11981
glpP 16077992 BG10185	5	glpD 16077995 BG10188 glpF 16077993 BG10186 glpQ 16077282 BG10646 glpT 16077283 BG10645 yhxA 16077991 BG10184
gltC 16078907 BG10810	2	gltA 16078906 BG10811 gltB 16078905 BG12594
gltR 16079720 BG11942	1	gltA 16078906 BG10811
gutR 16077681 BG10178	2	gutB 16077682 BG10177 gutP 16077683 BG12795
hpr 16078063 BG10659	14	appA 16078203 BG11087 appB 16078204 BG11088 appC 16078205 BG11089 appD 16078201 BG11085 appF 16078202 BG11086 aprE 16078094 BG10190 nprE 16078534 BG10448 oppA 16078208 BG10771 oppB 16078209 BG10772 oppC 16078210 BG10773 oppD 16078211 BG10774 oppF 16078212 BG10775 sinI 16079516 BG10753 yclF 16077435 BG12027
hrcA 16079603 BG10662	2	groEL 16077670 BG10423 groES 50812190 BG10422
hx1lR 16077416 BG11184	2	hx1lA 16077415 BG11183 hx1lB 16077414 BG11182
iolR 16081028 BG11364	3	iolS 16081029 BG11363 mmsA 16081027 BG11117 ydjk 16077690 BG12802
kdgR 16079270 BG11398	3	kdgA 16079268 BG11396 kdgK 16079269 BG11397 kdgT 16079267 BG11399
kipR 16077477 BG11214	6	kipA 50812187 BG14193 kipI 50812186 BG11231 ycsF 50812183 BG11227 ycsG 50812184 BG11228 ycsI 50812185 BG11230 ycsK 16077478 BG11232
lacR 16080470 BG12435	5	lacA 16080466 BG12439 yvfK 16080469 BG12436 yvFL 16080468 BG12437 yvFM 16080467 BG12438 yvFO 50812295 BG12440
levR 16079762 BG10677	1	levD 16079761 BG10316
lexA 16078848 BG10678	4	dinB 16077630 BG10539 tagC 16080630 BG10453 uvrA 16080570 BG10502 uvrB 16079901 BG10349
licR 16080911 BG11346	1	licB 16080910 BG11347
licT 16080959 BG10474	2	bglP 16080978 BG10934 bglS 16080958 BG10476
lmrA 16077337 BG12612	1	lmrB 16077336 BG12613
lrpA 16077572 BG12122	1	glyA 16080743 BG10944
lrpB 16077573 BG12123	1	glyA 16080743 BG10944
lytR 16080618 BG10404	3	lytA 16080617 BG10405 lytB 16080616 BG10406 lytc 16080615 BG10407
med 50812218 BG13126	1	comK 16078106 BG11059
mntR 16079508 BG11702	5	ydaR 16077503 BG12065 ytgA 16080129 BG13851 ytgB 16080128 BG13852 ytgC 16080127 BG13853 ytgD 16080126 BG13854
mta 16080713 BG12482	4	blt 16079712 BG10905 bmr 16079457 BG10303 htpG 16081033 BG11359 ydfK 16077612 BG12158
mtrB 16079334 BG10278	4	pabA 16077143 BG10138 trpE 16079325 BG10287 ycbK 16077323 BG11166 yhaG 16078065 BG12983
paiA 16080268 BG10695	1	nprE 16078534 BG10448
paiB 16080267 BG10696	1	nprE 16078534 BG10448
perR 16081061 BG12227	12	ahpC 16081061 BG11385 ahpF 16081062 BG11204 fur 16079409 BG11766 hemA 16079869 BG10340 hemB 16079865 BG10344 hemC 16079867 BG10342 hemD 16079866 BG10343 hemL 16079864 BG10345 hemX 16079868 BG10341 katA 16077947 BG10849 mrgA 16080351 BG10864 ykvW 16078449 BG13325
phoP 16079963 BG10363	35	glpQ 16077282 BG10646 phoA 16078006 BG10183 phob 16077641 BG10697 phod 16077331 BG11174 phoR 16079962 BG10364 pstA 16079552 BG11377 pstBA 16079551 BG11378 pstBB 16079550 BG11379 pstC 16079553 BG11376 pstS 16079554 BG11375 resA 16079372 BG10531 resB 16079371 BG10532

		resC 16079370 BG10533 resD 16079369 BG10534 resE 16079368 BG10535 tagA 16080628 BG10450 tagB 16080629 BG10451 tagD 16080627 BG10449 tagE 16080626 BG10724 tagF 16080625 BG10725 tuaA 16080614 BG12688 tuaB 16080613 BG12689 tuaC 16080612 BG12690 tuaD 16080611 BG12691 tuaE 16080610 BG12692 tuaF 16080609 BG12693 tuaG 16080608 BG12694 tuaH 16080607 BG12695 ydhF 16077640 BG12183 yhax 50812207 BG13000 yhbH 16077963 BG11238 yjbC 16078214 BG13132 yjbD 16078215 BG13133 ykoL 16078398 BG13257 yttP 16080015 BG13927
pucR 16080295 BG13983	15	gde 16078382 BG13240 pucA 16080304 BG13992 pucB 16080303 BG13991 pucC 16080302 BG13990 pucD 16080301 BG13989 pucE 16080300 BG13988 pucH 16080294 BG13982 pucJ 16080296 BG13984 pucK 16080297 BG13985 pucL 16080298 BG13986 pucM 16080299 BG13987 ureA 16080719 BG11981 yurG 16080305 BG13993 yurH 16080306 BG13994 ywoE 16080700 BG12492
purR 16077115 BG10110	22	folD 16079487 BG11711 glyA 16080743 BG10944 guac 16080266 BG12392 nusB 16079488 BG11710 pbuG 16077704 BG12811 pbuX 16079264 BG11080 purA 16081094 BG10002 purB 16077717 BG10707 purC 16077713 BG10703 purD 16077721 BG10711 purE 16077712 BG10700 purH 16077720 BG10710 purK 16077711 BG10701 purL 16077716 BG10705 purM 16077718 BG10708 purN 16077719 BG10709 purQ 16077715 BG10706 purS 16077714 BG10704 pyrP 16078612 BG10992 xpt 16079265 BG11079 yabJ 16077116 BG10111 ytiP 16080051 BG13864
pyrR 16078611 BG10712	1	pyrP 16078612 BG10992
resD 16079369 BG10534	13	ctaA 16078551 BG10213 ctaB 16078552 BG10214 fnr 16080784 BG11343 hemZ 16081159 BG12999 hmp 16078369 BG11418 ldh 16077374 BG19003 nasD 16077399 BG11096 phoP 16079963 BG10363 qcrA 16079313 BG11325 qcrB 16079312 BG11326 qcrC 16079311 BG11327 resA 16079372 BG10531 sbo 16080788 BG12671
rocR 16081087 BG10723	3	rocA 16080830 BG10622 rocD 16081086 BG10722 rocG 16080831 BG10621
rok 16078488 BG13307	1	comK 16078106 BG11059
sacT 16080858 BG10593	4	sacA 16080855 BG10596 sacP 50812303 BG10595 sacX 16080892 BG10560 ywdA 16080854 BG10597
sacY 16080893 BG10559	1	sacX 16080892 BG10560
sinR 16079517 BG10754	6	aprE 16078094 BG10190 comK 16078106 BG11059 rok 16078488 BG13307 spoOA 16079478 BG10765 spoIIAA 16079404 BG10296 spoIIGA 16078595 BG10234
spoOA 16079478 BG10765	12	abrB 16077105 BG10100 argC 16078184 BG10191 dlTA 16080901 BG10551 kinA 16078463 BG10204 kinC 16078513 BG10989 rbsR 16080644 BG10876 sinI 16079516 BG10753 spoOF 16080766 BG10411 spoIIAA 16079404 BG10296 spoIIIE 16077132 BG10127 spoIIGA 16078595 BG10234 yqxM 16079520 BG11076
spoIID 16080695 BG10408	11	bofA 16077091 BG10087 cotA 16077697 BG10490 cotD 16079278 BG10493 cotX 16078241 BG10500 gerE 16079893 BG10355 spoIID 16080728 BG10766 spoIIIAA 16079499 BG10540 spoIVCA 16079630 BG10458 spoIVCB 16079629 BG10459 spoVD 16078581 BG10222 spoVE 16078585 BG10226
spoVT 16077124 BG10119	15	bofC 16079827 BG11917 csgA 16077276 BG11504 dacF 16079405 BG10295 gerAA 16080358 BG10385 gerBA 16080633 BG10640 gerD 16077223 BG10644 gpr 16079608 BG10438 sigG 16078597 BG10236 spoIVB 16079479 BG10311 spoVAA 16079401 BG10892 sspA 16080009 BG10786 sspB 16078040 BG10787 sspD 16078411 BG10788 sspE 16077932 BG10789 ycxE 16077460 BG11066
tenA 16078230 BG10791	4	aprE 16078094 BG10190 nprE 16078534 BG10448 phoA 16078006 BG10183 sacB 16080498 BG10388
tenI 16078231 BG10792	1	tenA 16078230 BG10791
tnrA 16078396 BG11805	31	alsT 16078873 BG11798 gabP 16077698 BG11328 glnH 16079797 BG11486 glnM 16079798 BG11487 glnP 16079799 BG11488 glnQ 16079796 BG11485 glnR 16078808 BG10424 gltA 16078906 BG10811 nasA 16077402 BG11093 nasB 16077401 BG11094 nasD 16077399 BG11096 nrgA 16080704 BG10869 oppA 16078208 BG10771 pel 16077823 BG10840 ptb 16079465 BG11722 pucJ 16080296 BG13984 ureA 16080719 BG11981 yccC 16077338 BG12755 ycsF 50812183 BG11227 ykzb 16078397 BG13330 yodF 16079016 BG13535 yttA 16080088 BG13924 ywdI 16080846 BG10605 ywdJ 16080845 BG10606 ywdK 16080844 BG10607 ywlF 16080745 BG10942 ywlG 16080744 BG10943 ywrD 16080663 BG12523 yxkC 16080936 BG12541 yycc 16081100 BG10007 yycC 16081099 BG10006
treR 16077849 BG11011	1	treP 16077847 BG11009
xpf 16078321 BG10998	10	xkdE 16078324 BG11540 xkdF 16078325 BG11541 xkdG 16078326 BG11542 xkdH 16078327 BG11543 xkdI 16078328 BG11544 xkdJ 16078329 BG11545 xkdK 16078330 BG11546 xkdM 16078331 BG11547 xtmA 16078322 BG10999 xtmB 16078323 BG11000
xre 16078316 BG10994	4	xkdB 16078317 BG10995 xkdC 16078318 BG10996 xkdD 16078319 BG10997 xtrA 16078320 BG11559
xylR 16078822 BG11986	2	xylA 16078823 BG10806 xynP 16078820 BG12262
ydbG 16077513 BG12074	1	dctP 16077514 BG12075

<b>ydiH</b>   16077664   BG12205	<b>4</b>	cydA   16080927   BG11925 cydB   16080926   BG11926 cydC   16080925   BG11927 cydD   16080924   BG11928
<b>yfhP</b>   16077928   BG12890	<b>1</b>	yfhQ   16077929   BG12891
<b>yfiA</b>   16077886   BG11847	<b>1</b>	malA   16077885   BG11839
<b>ykmA</b>   16078380   BG13239	<b>1</b>	yk1A   16078379   BG13238
<b>ylbO</b>   16078573   BG13367	<b>2</b>	cgeA   16079036   BG11193 cotY   16078240   BG10498
<b>yocG</b>   16078980   BG13520	<b>1</b>	des   16078978   BG13518
<b>yufM</b>   16080205   BG12348	<b>3</b>	maeN   16080210   BG12353 yf1S   16077824   BG12951 ywkA   16080758   BG11312
<b>ywfK</b>   16080817   BG10635	<b>2</b>	yvgQ   16080396   BG14099 yvgR   16080397   BG14100
<b>ywiD</b>   16080782   BG11345	<b>5</b>	alsS   16080654   BG10471 hemN   16079604   BG11395 hemZ   16081159   BG12999 ldh   16077374   BG19003 nasD   16077399   BG11096
<b>yycF</b>   16081093   BG10001	<b>4</b>	ftsA   16078592   BG10231 tagD   16080627   BG10449 ykvT   16078446   BG13322 yoch   16078981   BG13521
<b>zur</b>   16079565   BG11668	<b>3</b>	ycdH   16077354   BG12763 yciA   16077403   BG12019 yciC   16077405   BG12021

## ANEXO 3A. (Was translate to online web: [http://www.ccg.unam.mx/Computational\\_Genomics/TRNS/conservation/](http://www.ccg.unam.mx/Computational_Genomics/TRNS/conservation/))

Collection of non-redundant pairs of genes of the metabolic pathways defined according to the KEGG database in *E.coli* and *B. subtilis*.

## ANEXO 3B.

### Obtaining thresholds for identifying co-evolving TF-TG pairs in the TRNs by comparing against co-occurring pairs of genes in metabolic pathways.

An average of distances D1 and D2 was calculated for the complete non-redundant collection of pairs (P1-P2) in each genomes' pathways. However this average distance D1 or D2 is an over estimate of the extent of conservation for regulatory interactions so a (Average-standard deviation) was employed to generate significantly conserved interacting pairs. Since in metabolic interactions D1 and D2 are synonymous unlike Dtf and Dtg in regulatory interactions we used a final threshold of

$$T = \{(\langle D1 \rangle - STD1) + (\langle D2 \rangle - STD2)\} / 2$$



Where  $\langle D1 \rangle$  and  $\langle D2 \rangle$  are the average values of D1 and D2 for all pairs and STD1 and STD2 are the standard deviations of D1 and D2.

To best represent a threshold to obtain highly conserved pairs. The process was repeated for both the genomes using the respective known pathways documented in Kegg database.

Mesares	KEGG in <i>Escherichia coli</i>	KEGG in <i>Bacillus subtilis</i>
AVG 1	<b>0.472009789418263</b>	<b>0.480096384161564</b>
AVG 2	<b>0.517286194952669</b>	<b>0.519944735263887</b>
STD 1	<b>0.281274994523379</b>	<b>0.321133581894223</b>
STD 2	<b>0.279065684017891</b>	<b>0.310716106014003</b>
FINAL SC 1	<b>0.190734794894885</b>	<b>0.158962802267342</b>
FINAL SC 2	<b>0.238220510934779</b>	<b>0.209228629249884</b>
THRESHOLD	<b>0.214477652914832</b>	<b>0.184095715758613</b>

## ANEXO 4B.

Figures showing that the distributions of the quantities ( $TF = TG$ ,  $TF > TG$  and  $TF < TG$ ) in the randomized networks (based on 1000 random networks) are normal. In each case we found that the distribution can be easily approximated to normal and hence tests used for normal distributions were employed.



<i>Escherichia coli</i> K12			<i>Bacillus subtilis</i>		
<i>Threshold: 0.2145</i>			<i>Threshold: 0.1841</i>		
Categoría	Interacciones	Z-score (P-value)	Categoría	Interacciones	Z-score (P-value)
<b>TF = TG</b>	<b>15</b>	<b>5.44 (&lt; 0.0001)</b>	<b>TF = TG</b>	<b>15</b>	<b>2.99 (0.0028)</b>
<b>TF &gt; TG</b>	<b>813</b>	<b>-5.06 (&lt; 0.0001)</b>	<b>TF &gt; TG</b>	<b>363</b>	<b>3.24 (0.0012)</b>
<b>TF &lt; TG</b>	<b>759</b>	<b>3.68 (0.00023)</b>	<b>TF &lt; TG</b>	<b>349</b>	<b>-3.60 (0.00032)</b>

**ANEXO 4A.** (Was translate to online web: [http://www.ccg.unam.mx/Computational\\_Genomics/TRNS/conservation/](http://www.ccg.unam.mx/Computational_Genomics/TRNS/conservation/))

Figure that represent the methodology to reconstruct random TRNs from *E.coli* and *B. subtilis*.

## **ANEXO 5.**

## Conserved interactions across bacteria from the perspective of the TRNs of *E. coli* and *B. subtilis*.




<b>GlpR</b>	It is the repressor specifically bound to control regions of the glpD, glpFK, glpTQ, and glpACB operons. The binding of DNA by the repressor was diminished in the presence of sn-glycerol 3-phosphate. It belongs to the DeoR family of transcriptional regulators.	8	GlpD, glpF, glpK																		
<b>OxyR*</b>	This regulator participates in controlling several genes involved in the <b>response to oxidative stress</b> and the production of surface proteins that control the colony morphology and auto-aggregation ability. It regulates intracellular hydrogen peroxide levels by activating genes such dps, fur, and katG. OxyR is negatively autoregulated. The protein belongs to the LysR family.	13	ahpC, dps, fur, sufB, sufC, sufS																		

**Table. Biological distribution and additional information about the regulatory interactions well conserved in bacteria.** \* means that transcription factor is regulated by itself (autoregulation). **GPE:** gamma proteobacteria enterobacteria, **GP:** other gamma proteobacteria, **BP:** beta proteobacteria, **EP:** epsilon proteobacteria, **DP: delta proteobacteria**, **AP:** alfa proteobacteria, **BF:** bacillales, **LF:** lactobacillales, **CF:** clostridia, **MF:** mollicutes, **ACT:** actinobacteria, **FU:** fuseobacteria, **PLA:** planctomyces, **CHL:** chlamydias, **SPI:** spirochetes, **CYA:** cyanobacteria, **GS:** green sulfur bacteria, **NGS:** non green sulfur bacteria, **DEI:** deinococcus-thermus, **HYP:** hyperthermophilic bacteria, **A:** archaea.


## ANEXO 6A.

Distribution of TF and TG orthologs for *Escherichia coli K12* and their  $C_{TF} - C_{TG}$  index values in 204 complete genomes.




## ANEXO 6B.

Distribution of TF and TG orthologs for *Bacillus subtilis* and their  $C_{TF} - C_{TG}$  index values in 204 complete genomes.




## ANEXO 8A.


The regulatory adaptability and structural flexibility represented in the Crp-Fnr scaffold has led to the evolution of an important group of physiologically versatile transcription factors (Körner *et al.*, 2003).



**The central role of FixK<sub>2</sub> in nitrogen fixation and the respiratory metabolism of *B. japonicum*.**



**Signals processed by regulators (orthologs and not orthologs) of the Crp-Fnr family.**



**Regulatory cascade of the activated gene programs from FNR in *B. subtilis* under low oxygen tension.**

## ANEXO 8B.

### Is the global regulatory role associated with *E. coli* Lrp limited to enteric bacteria?

To probe this question Friedberg *et al.* (2001) investigated LrfB, an Lrp-related protein from *Haemophilus influenzae* that shares 75% sequence identity with *E. coli* Lrp (highest sequence identity among 42 sequences compared). A strain of *H. influenzae* having an *lrfB* null allele grew at the wild-type growth rate but with a filamentous morphology. A comparison of two-dimensional (2D) electrophoretic patterns of proteins from parent and mutant strains showed only two differences (comparable studies with *lrp1* and *lrp* *E. coli* strains by others showed 20 differences). The abundance of LrfB in *H. influenzae*, estimated by Western blotting experiments, was about 130 dimers per cell (compared to 3,000 dimers per *E. coli* cell). LrfB expressed in *E. coli* replaced Lrp as a repressor of the *lrp* gene but acted only to a limited extent as an activator of the *ilvIH* operon. Thus, although LrfB resembles Lrp sufficiently to perform some of its functions, its low abundance is consonant with a more local role in regulating but a few genes, a view consistent with the results of the 2D electrophoretic analysis. Friedberg *et al.* (2001) speculate that an Lrp having a global regulatory role evolved to help enteric bacteria adapt to their ecological niches and that it is unlikely that Lrp-related proteins in other organisms have a broad regulatory function.




FIG. 1. Comparison of Lrp-related proteins from a number of microorganisms. (A) Amino acid identities for pairwise combinations of sequences. Amino acid sequences of the following Lrp-related proteins were compared in pairwise combinations using the Genetics Computer Group GAP alignment program (12). (B) Highly conserved positions in Lrp-related proteins. The Genetics Computer Group Pileup program (12) was used to align sequences identified in the legend above by a tilde. The sequence of *E. coli* Lrp is shown, with asterisks designating amino acids that are completely conserved among the 23 proteins. Cases in which a position is limited to only two amino acids are also shown. The helix-turn-helix region is identified with an overline.





FIG. 2. Genes related to *lrp* in *E. coli* and *H. influenzae*. Each horizontal line represents the genome of *E. coli* or *H. influenzae* on a scale of 100 units. Arrows represent direction of transcription. The *lrp*-related genes *lrp*, *asnC*, *ybaO*, *lrfA* (HI0224), and *lrfB* are shown together with flanking genes. The percent predicted amino acid identities of proteins encoded by pairs of *lrp*-related genes is indicated. *ftsK*\* (HI1592, HI1593, HI1594, and HI1595) is related to *E. coli* *ftsK* as follows: HI1595 is weakly related to the N-terminal amino acids of FtsK (unfiltered BLAST score, 110), and HI1592 is highly related to the C terminus of FtsK (BLAST score, 1358). Orthologs are homologous genes in different organisms that encode proteins with the same function and that have evolved by direct, vertical descent. Two genes are considered to be orthologs if their predicted amino acid sequences fulfill the following criteria (37): they show higher similarity to each other than to other proteins in either organisms, they show a higher similarity to each other than to homologs from phylogenetically more distant organisms, and they align throughout most of their lengths. In addition, an orthologous relationship between two genes is strengthened if the two are flanked on one or both sides by orthologous gene pairs.






FIG. 3. Binding of Lrp and LrfB to sites upstream of the *ilvIH* promoter as visualized by gel retardation. A  $^{32}$ P-labeled 276-bp DNA fragment from a region upstream of the *E. coli* *ilvIH* promoter containing six binding sites for Lrp was mixed with no protein (lane 1), purified 6 $\times$  His-LrfB (lanes 2 to 5), purified 6 $\times$  His-LrfB $\Delta$ 60 (lacking 60 C-terminal amino acids) (lane 5), and purified 6 $\times$  His-Lrp (lanes 7 to 10), and samples were fractionated by electrophoresis. The concentrations (nanomolar) of proteins are indicated. For the experiment with Lrp, the faster-moving band contains Lrp bound to sites 1 and 2, and the slower-moving band contains Lrp bound to sites 1, 2, 3, 4, 5, and 6 (38).




FIG. 5. Amount of LrfB in *H. influenzae* (A) and in *E. coli* strain CV1536 (B) as determined by Western blotting. A standard curve prepared using 6 $\times$  His-LrfB was employed to estimate that 0.073% of the total protein in *H. influenzae* is LrfB. The number of dimers per cell was calculated assuming that the total protein per unit volume is the same for *E. coli* and *H. influenzae*. The following parameters were used in the calculation: total protein per *E. coli* cell, 0.156 pg (28); volume of an *E. coli* cell,  $0.87 \times 10^{-12}$  ml, calculated from the weight of a cell together with the densities of the components of a cell (28) (a similar number is derived from assuming that the dimensions of an *E. coli* cell are 0.75 by 2  $\mu$ m); volume of an *H. influenzae* cell,  $0.636 \times 10^{-12}$  ml, calculated assuming dimensions of 0.3 by 1  $\mu$ m (27); LrfB dimer molecular mass, 37.8 kDa.




FIG. 4. 2D gel analysis of proteins in extracts of wild-type (A) and *lrfB*::kan (B) strains of *H. influenzae*. For the isoelectric focusing dimension, the anode is on the left. Cells were grown in M1c medium and pulse-labeled with [ $^{35}$ S]methionine. Arrows indicate the positions of the two spots that were reproducibly different in the two strains.

TABLE 2. LrfB activates expression from the *E. coli* *ilvIH* promoter and represses expression from the *lp* promoter

Strain <sup>a</sup>	<i>lp</i> or <i>lrfB</i> allele on:		Promoter- <i>lacZ</i> fusion	Addition to medium <sup>b</sup>	Sp act of $\beta$ -galactosidase <sup>c</sup>	Relative sp act (%)
	Chromosome	Plasmid				
CV975	<i>lp</i> <sup>+</sup>		<i>PilvIH</i>		$359 \pm 20$	100
CV975	<i>lp</i> <sup>+</sup>		<i>PilvIH</i>	Leu	$37.4 \pm 2.6$	10
CV1535	<i>lp</i> -35::Tn10		<i>PilvIH</i>		$3.0 \pm 2.1$	0.83
CV1536	<i>lp</i> -35::Tn10	<i>lrfB</i>	<i>PilvIH</i>		$43.3 \pm 9.1$	12
CV1536	<i>lp</i> -35::Tn10	<i>lrfB</i>	<i>PilvIH</i>	Leu	$6.6 \pm 0.34$	1.8
CV1534	<i>lp</i> -35::Tn10		<i>Plp</i>		$774 \pm 53$	100
CV1528	<i>lp</i> -35::Tn10	<i>lrfB</i>	<i>Plp</i>		<0.5	<0.06

<sup>a</sup> Strains CV975, CV1535, and CV1536 were grown to log phase in sSSA minimal medium containing 50  $\mu$ g of ampicillin per ml (except for CV975). Strains CV1534 and CV1528 were grown in LB medium containing 100  $\mu$ g of ampicillin per ml.

<sup>b</sup> When present, leucine was at 50  $\mu$ g/ml.

<sup>c</sup> Specific activity is in Miller units. Data are averages  $\pm$  standard deviations of at least two different experiments, each performed in duplicate.

## ANEXO 8C.

### Role of CcpA in Regulation of the Central Pathways of Carbon Catabolism in *Bacillus subtilis*.

The *Bacillus subtilis* two-dimensional (2D) protein index contains almost all glycolytic and tricarboxylic acid (TCA) cycle enzymes, among them the most abundant housekeeping proteins of growing cells. Therefore, a comprehensive study on the regulation of glycolysis and the TCA cycle was initiated (Tobisch *et al.*, 1999). Whereas expression of genes encoding the upper and lower parts of glycolysis (*pgi*, *pfk*, *fbaA*, and *pykA*) is not affected by the glucose supply, there is an activation of the glycolytic *gap* gene and the *pgk* operon by glucose. This activation seems to be dependent on the global regulator CcpA, as shown by 2D polyacrylamide gel electrophoresis analysis as well as by transcriptional analysis. Furthermore, a high glucose concentration stimulates production and excretion of organic acids (overflow metabolism) in the wild type but not in the *ccpA* mutant. Finally, CcpA is involved in strong glucose repression of almost all TCA cycle genes. In addition to TCA cycle and glycolytic enzymes, the levels of many other proteins are affected by the *ccpA* mutation. Tobisch *et al.* (1999), suggest (i) that *ccpA* mutants are unable to activate glycolysis or carbon overflow metabolism and (ii) that CcpA might be a key regulator molecule, controlling a superregulon of glucose catabolism.




FIG. 1. Main pathways of carbohydrate metabolism. (A) Silver-stained 2D gel showing identified proteins which are involved in glycolysis (Pgi, Pfk, FbaA, Tpi, Gap, Pgk, Pgm, Eno), pyruvate dehydrogenases (PdhA, PdhB, PdhC, PdhD), the TCA cycle (CitZ, CitB, CitC, OdhA, PdhD, SucC, SucD, SdhA, CitG, CitH), and overflow metabolism (Pta, AckA). (B) Schematic representation of glycolysis and the TCA cycle. Enzymes and metabolites are indicated. Note that not all the proteins of these pathways are identified on 2D gels.




FIG. 4. Quantitative analysis of mRNAs of glycolytic and TCA cycle enzymes. Different concentrations of RNA (1 and 0.5  $\mu$ g) from *B. subtilis* IS58 and BGW2 were blotted onto nylon membranes and hybridized with probes specific for the genes indicated. The mRNA amount obtained for IS58 in the presence of 0.1% ribose was set at 1.

## Role of CRP in Regulation of the Central Pathways of Carbon Catabolism in *Escherichia coli*.

Even though transcriptional regulation plays a key role in establishing the metabolic network, the extent to which it actually controls the in vivo distribution of metabolic fluxes through different pathways is essentially unknown. Based on metabolism-wide quantification of intracellular fluxes, Perrenoud and Sauer (2005) systematically elucidated the relevance of global transcriptional regulation by ArcA, ArcB, Cra, Crp, Cya, Fnr, and Mlc for aerobic glucose catabolism in batch cultures of *Escherichia coli*. Knockouts of ArcB, Cra, Fnr, and Mlc were phenotypically silent, while deletion of the catabolite repression regulators Crp and Cya resulted in a pronounced slow-growth phenotype but had only a nonspecific effect on the actual flux distribution. Knockout of ArcA-dependent redox regulation, however, increased the aerobic tricarboxylic acid (TCA) cycle activity by over 60%. Like aerobic conditions, anaerobic derepression of TCA cycle enzymes in an ArcA mutant significantly increased the in vivo TCA flux when nitrate was present as an electron acceptor. The in vivo and in vitro data demonstrate that ArcA-dependent transcriptional regulation directly or indirectly controls TCA cycle flux in both aerobic and anaerobic glucose batch cultures of *E. coli*. This control goes well beyond the previously known ArcA-dependent regulation of the TCA cycle during microaerobiosis.




FIG. 1. Biochemical reaction network for central carbon metabolism in *E. coli*. The arrowheads indicate the assumed reaction reversibility. The inset provides an overview of central metabolic genes that are regulated by the global regulators which we investigated. Negative transcriptional regulation and positive transcriptional regulation are indicated by minus signs and plus signs that follow the gene abbreviations, respectively. Only regulated genes are indicated in the network for clarity.




FIG. 4. Metabolic flux distribution in the Crp mutant (bottom values) and the parent strain (top values) (A) and in the Cya mutant (bottom values) and the parent strain (top values) (B) during exponential aerobic growth on glucose. For clarity only the lower part of metabolism is shown. Net molar fluxes (expressed in millimoles per gram per hour) were determined by  $^{13}\text{C}$ -constrained flux analysis from two separate experiments with 100% [ $1-^{13}\text{C}$ ]glucose and with a mixture of 20% [ $\text{U}-^{13}\text{C}$ ]glucose and 80% unlabeled glucose. In all cases the standard deviation was less than 0.2  $\text{mmol g}^{-1} \text{h}^{-1}$ . Fluxes to biomass building blocks and extracellular products are enclosed in boxes.