

Identificación *in silico* de un grupo de secuencias ortólogas conservadas (COS) de *Ipomoea batatas*

In silico prediction of conserved ortholog set (COS) sequences from *Ipomoea batatas*

Christian Solís-Calero

Centro Internacional de la Papa (CIP), P.O. Box 1558, Lima 12, Perú.
Email Christian Solís Calero: csolis@esan.org.pe

Resumen

En el presente trabajo se describe una serie de procedimientos bioinformáticos para la predicción de un grupo de secuencias ortólogas conservadas (COS) de *Ipomoea batatas*, así como la evaluación de su potencial utilidad para la generación de marcadores moleculares y estudios de diversidad en esta especie. Con ese propósito usando los programas BLAST X y TBLASTN se realizó una comparación recíproca por similitud entre secuencias ESTs procedentes de librerías de cDNAs de *Ipomoea batatas*, propias o disponibles de modo público en la base de datos GenBank, con secuencias COS de *Arabidopsis thaliana*. La anotación funcional de las secuencias COS predichas en *Ipomoea batatas* se realizó usando los programas BLASTX, INTERPROSCAN y PSI-BLAST. Se obtuvieron en total 204 secuencias COS candidatos de *Ipomoea batatas*, siendo 16 secuencias provenientes de una librería generada a partir de raíces de reserva. Se evaluó de modo computacional el polimorfismo de las secuencias COS de raíces de reserva, obteniéndose SNPs en 8 secuencias, y secuencias repetidas en tandem en una de ellas.

Palabras clave: COS, *Ipomoea batatas*, genes de baja copia, ortólogos, ESTs.

Abstract

We develop some bioinformatics procedures to predict Conserved Ortholog Set (COS) sequences from *Ipomoea batatas*, and evaluate their usefulness for molecular markers and diversity studies of this species. We predict orthology relationship between *Ipomoea batatas* ESTs sequences and *Arabidopsis thaliana* COS sequences, according to Best Bidirectional Hits (BBHs) criteria, realizing similarity comparison using BLAST X and TBLASTN programs. We obtained a set of 204 putative COS sequences, 16 of them belonged to storage roots. Functional annotation of sweet potato predicted sequences COS was realized using BLASTX, INTERPROSCAN and PSI-BLAST programs. We evaluate possible polymorphisms in COS candidate sequences, finding SNPs in eight sequences and tandem repeats in one of them.

Keywords: COS, *Ipomoea batatas*, ortholog, low copy genes, ESTs.

Presentado: 22/02/2007
Aceptado: 06/01/2008
Publicado online: 21/07/2008

Introducción

Los ortólogos son definidos como genes de diferentes especies que comparten un ancestro común por especiación. Por contraste, los genes parálogos son copias duplicadas dentro de un genoma que pueden ser producidos por el fenómeno de poliploidización o duplicaciones en tandem (Gogarten & Olenzki, 1999, Sonnhammer & Koonin, 2002) (Fig. 1).

Actualmente, debido a la disponibilidad cada vez mayor de bases de datos de secuencias genómicas y de ESTs, la predicción de la relación de ortología entre genes de diferentes especies puede ser realizada mediante métodos bioinformáticos, incluso entre genes de especies tan divergentes en las que por estudios experimentales antes no se podía predecir tal relación (Pennisi, 1998, Ku et al., 2000). Basados en ello Fulton et al. (2002) introdujeron el concepto de "grupo de ortólogos conservados" (COS), que son secuencias marcadoras obtenidas del procesamiento de la información de las bases de datos de secuencias biológicas. Estas secuencias corresponden a genes de plantas que se han mantenido conservados y en un bajo número de copias en sus genomas, desde los últimos ancestros comunes que comparten las plantas con flores. El diseño de iniciadores de PCR sobre estas secuencias puede permitir su uso para la obtención de marcadores moleculares basados en secuencias Ej: (CAPs, SSRs) y estudios de diversidad, incluso en especies relacionadas a la de origen de la secuencia (Kozik & Michelmore, 2002).

Los esfuerzos para la generación de nuevos marcadores moleculares en *Ipomoea batatas* son importantes, porque permitirían aumentar la densidad de los mapas genéticos recién generados en esta especie. Las secuencias COS a su vez pueden ser la base para estudios de evolución molecular que en *Ipomoea batatas*

puedan determinar de modo más preciso su biogeografía y sus centros de origen. Otro de los propósitos de este trabajo es presentar un ejemplo de como se puede aprovechar la gran cantidad de información de secuencias depositada en las bases de datos biológicas, así como programas bioinformáticos, que son accesibles libremente por toda la comunidad científica a través de Internet, o pueden ser escritos según los requerimientos específicos de la investigación usando lenguajes de programación como Perl y PHP (Stajich et al., 2002).




Figura 1. Relaciones de homología entre los genes

Tabla 1. Descripción de las secuencias ESTs usadas

Origen de Librería	Línea celular - Cultivar	Estadio	No de ESTs usados	Institución generadora del Proyecto
Raíz de Reserva	Kyukei-63	Maduro	412	Centro Internacional de la Papa Lima Perú, Potato Research Center, Agriculture and Agri-Food Canada.
Raíz Fina	Kyukei-63	Maduro	365	
Raíz de Reserva	Jinhongmi	Estadio temprano de desarrollo	2859	Plant Molecular Breeding, Graduate School of Biotechnology. Korea University, Seoul 136-701, South Korea.
Hojas	---	Maduro	1079	Department of Biotechnology ARC. Research GesmbH A2444 Seibersdorf, Austria.
Plántula entera	Jewel	Maduro	215	USDA/ARS, Plant Genetic Resources, 1109 Experiment Street, Griffin, GA 30223, USA.

Materiales y métodos

Bases de datos de ESTs de *Ipomoea batatas*

Se obtuvieron secuencias ESTs correspondientes a varias librerías de ESTs de *Ipomoea batatas* a través del National Center for Biotechnology Information (NCBI: <http://www.ncbi.nlm.nih.gov>).

Asimismo se dispuso de secuencias ESTs pertenecientes a 2 librerías generadas en proyectos del CIP. La información sobre las librerías usadas se encuentra descrita en la Tabla 1. Las secuencias COS de *Arabidopsis thaliana* fueron obtenidas del Compositae Genome Project Database (Kozik & Michelmore, 2002). Para disminuir la redundancia de secuencias semejantes en cada grupo de ESTs, estas secuencias según su origen fueron sometidas a un proceso de ensamblaje usando el programa CAP3 (Huang & Madan, 1999), obteniéndose como resultado *contigs* en el caso de secuencias redundantes, y *singletons* si las secuencias eran únicas. Las secuencias ESTs, así como la información derivada de su procesamiento fueron depositadas en una base de datos llamada Kumara ESTs, desarrollada usando el paquete de programas XAMPP (que incluye Apache, MySQL, PHP y Perl).

Determinación de secuencias ortólogas

Para la identificación de ortólogos se siguió el criterio de *Best Bidirectional Hits* (BBHs) (8); se realizaron dos búsquedas de similitud entre las secuencias ESTs de *Ipomoea batatas* y las secuencias de aminoácidos correspondientes a los genes COS de *Arabidopsis thaliana*, usando localmente los programas BLASTX y TBLASTN. Los parámetros de búsqueda fueron en ambos casos $W=12$, matriz: BLOSUM62, $T(\text{threshold})=11$, mínimo valor de $E=10^{-6}$, tamaño teórico del query= 1000. Los resultados de la búsqueda BLAST fueron posteriormente resumidos usando un programa en Perl escrito por nosotros. Se seleccionaron como secuencias COS candidatos, las secuencias ESTs que presentaron en los alineamientos con las secuencias COS de *Arabidopsis*,

valores E inferiores a 10^{-6} y porcentajes de identidad superiores al 30% y longitudes de alineamiento mayor igual a 70 aminoácidos y que no presentaron similitud significativa con más de una secuencia de *Arabidopsis*. Los resultados de los análisis de similitud fueron procesados mediante otros programas Perl previamente escritos, obteniendo los archivos de entrada del programa Genome Pixelizer (Kozik et al., 2002), que permitió visualizar la distribución de las secuencias COS candidato de *Ipomoea batatas* sobre el genoma de *Arabidopsis thaliana*.

Anotación Funcional

La anotación funcional de las secuencias COS predichas en *Ipomoea batatas* se realizó usando localmente el programa BLASTX (Altschul et al., 1997), y de modo *online* mediante los programas INTERPROSCAN (Quevillon et al., 2005) localizado en: <http://www.ebi.ac.uk/InterProScan/>, y PSI-BLAST (Altschul & Koonin, 1998) localizado en: <http://www.ncbi.nlm.nih.gov/BLAST/>.

Predicción de polimorfismos en las secuencias COS candidato

Con el objetivo de evaluar la posible utilidad de las secuencias COS obtenidas para la generación de marcadores moleculares y estudios de diversidad, se realizó la predicción computacional de polimorfismos de tipo SNPs y repeticiones en *tandem* en el interior de las secuencias COS correspondientes a las secuencias *contigs* de raíces de reserva.

Cada secuencia se comparó contra la base de datos EST del NCBI usando el programa BLASTN. De esta base de datos Se obtuvieron las secuencias de *Ipomoea batatas* cuyos alineamientos presentaron valores de E menores a 10^{-30} , y longitudes de alineamiento que superaran el 80% de la longitud de la secuencia. Estas secuencias fueron agrupadas con los ESTs que formaban

Tabla 2. Anotación Funcional usando BLASTX tomando como Base de datos las secuencias COS predichas para *Arabidopsis thaliana*.

Anotación funcional	Origen de las librerías de ESTs					
	Raíz de reserva	Raíz fina	Raíz de reserva inmadura	Hojas	Plántula entera	To-
Genes relacionados al Metabolismo de Carbohidratos	2	1	1	1	5	10
Genes relacionados a defensa contra Patógenos o stress	3	3	6	6	2	20
Otros Genes anotados	5	11	14	38	16	84
Genes No anotados	6	9	23	51	1	90
Total	16	24	44	96	24	204

Tabla 3. Anotación funcional para las secuencias predichas usando la librería de ESTs provenientes de raíces de reserva de *Ipomoea batatas*

Código del EST	Identificador COS	E-value	% Identidad	Longitud del alineamiento	Anotación funcional	Programa usado
Contig-S106	At2g18290	1E-55	66	158	Sub Unidad E3 de la Proteína Ubiquitina ligasa	INTERPRO
EB32-H1.e	At2g32080	1E-54	67	153	Pur- α proteína de unión específica a DNA y RNA	BLASTX
Contig-S092	At1g19530	1E-15	37	137	Proteína expresada	No anotada
Contig-S125	At3g63330	1E-06	32	128	Tirosina quinasa	INTERPRO
EB32-D7.e	At1g03490	1E-08	31	115	Proteína del Meristemo no apical (NAM).	BLASTX
Contig-S199	At2g26590	1E-34	59	114	Proteína regulatoria de la adhesión celular ARM_1,	PSI-BLAST
EB30-H4.e	At4g39280	1E-55	86	111	Fenilalanina t-RNA sintetasa	BLASTX
EB32-D8.e	At2g31980	1E-06	24	106	Inhibidor de cisteina proteasas	BLASTX
Contig-S112	At1g31812	1E-26	65	84	Proteína de unión a Acil-CoA (ACBP)	BLASTX
EB30-E1.e	At4g13400	1E-15	46	83	Proteína expresada	No anotada
EB28-C1.e	At1g65820	1E-33	73	80	Glutation S transferasa microsomal	BLASTX
EB31-G3.b	At5g09340	1E-07	36	79	Ubiquitina	BLASTX
Contig-S041	At4g10130	1E-10	43	78	Proteína de unión a DNA	BLASTX
Contig-S172	At1g77290	1E-09	39	73	Dehalogenasa	BLASTX
EB28-H3.e	At4g37830	1E-25	70	72	Citocromo c oxidasa	INTERPRO
EB29-B3.e	At5g47570	1E-25	70	70	Proteína expresada	No anotada

cada *contig*, y ensambladas usando el programa CAP3 (Huang & Madan, 1999). Usando los resultados del ensamblaje de secuencias, se realizó la predicción de: SNPs usando el programa AutoSNP (Barker et al., 2003); microsatélites con el programa Sputnik (Jewell et al., 2006); y de las repeticiones en tandem con el programa Tandem Repeats Finder (Benson, 1999).

Resultados

Se obtuvieron en total 204 secuencias COS candidatos de *Ipomoea batatas*, siendo 16 secuencias provenientes de la librería generada a partir de raíces de reserva, los detalles se muestran en las tablas 2 y 3. La distribución de todas las secuencias COS

candidato de *Ipomoea batatas* sobre el genoma de *Arabidopsis thaliana* se pueden visualizar en la figura 2. Solo se pudo predecir polimorfismos de secuencia SNPs en ocho secuencias, y de secuencias repetidas en *tandem* en solo una secuencia, los detalles se muestran en la tabla 4.

Discusión

La definición de secuencias COS considera que sean genes de baja copia, y es por esa característica que estas secuencias pueden ser de utilidad en estudios de evolución molecular, biodiversidad y generación de marcadores moleculares (Fulton et al., 2002). Para asegurar esta característica, en la predicción de secuencias




Figura 2. Distribución de las secuencias COS predichas de *Ipomoea batatas* sobre el genoma de *Arabidopsis thaliana*, en base a análisis de similaridad (1 centiMorgan equivale aproximadamente a 1 megabase).

Tabla 4. Predicción computacional de polimorfismos en las secuencias COS candidato de *Ipomoea batatas*.

Identificador COS	N° de secuencias	Longitud del contig (pb)	SNPs predichos				N.° de Repeticiones en tandem
			Transiciones	Transversiones	Delecciones	Total	
At2g18290	5	898	0	0	0	0	0
At2g32080	5	1393	0	0	0	0	0
At1g19530	8	839	38	19	9	66	0
At3g63330	2	374	0	0	0	0	0
At1g03490	5	1198	0	0	0	5	0
At2g26590	3	892	0	0	0	0	2
At4g39280	1	-	-	-	-	-	0
At2g31980	6	526	1	4	0	5	0
At1g31812	8	718	19	39	9	67	0
At4g13400	2	885	0	0	0	0	0
At1g65820	9	805	16	8	5	29	0
At5g09340	26	1303	71	77	159	238	0
At4g10130	3	551	0	0	0	0	0
At1g77290	2	718	0	0	0	0	0
At4g37830	13	693	13	6	30	49	0
At5g47570	8	843	64	42	17	123	0

COS propias de camote hemos usado como referencia las secuencias COS de *Arabidopsis thaliana*, en la que por análisis de su genoma completo, se ha determinado que esas secuencias son de baja copia (Kozik & Michelmore, 2002).

La relación de ortología se estableció entre las secuencias COS de *Arabidopsis* y secuencias ESTs de *Ipomoea batatas* usando el criterio de Best Bidireccional Hits (BBHs). Según esta definición, dos genes, de dos organismos diferentes, respectivamente, son ortólogos si luego de una búsqueda de similaridad en ambos genomas ambas muestran ser en forma recíproca, más similares entre sí respecto a otros genes (Zheng et al., 2005). A esta definición nosotros incluimos tres restricciones más: que la similaridad tenga valores de E-value superiores a 1×10^{-6} , un porcentaje de identidad superior al 25% y una longitud de alineamiento mayor o igual a 70 aminoácidos. Hemos considerado estos valores porque son cercanos a los sugeridos por otros autores (Claverie & Notredame, 2003), porque la longitud mínima aceptable para un EST es de 200 pb (cercano al valor de 70 aminoácidos), y porque disminuyen la probabilidad de registrar como COS a secuencias que presentan similaridad pero solo por compartir dominios comunes a varias proteínas y que no necesariamente revelan que las secuencias comparadas tengan una relación de homología (ancestro común).

Debemos considerar que los linajes de *Arabidopsis thaliana* e *Ipomoea batatas* se separaron hace 100 a 150 millones de años (14) por lo que la relación de similaridad entre dos genes ortólogos no tiene que ser necesariamente alta. Por ello hemos empleado una comparación DNA (ESTs) - proteínas (Secuencia COS *Arabidopsis*). Ésta comparación a diferencia de las comparaciones DNA-DNA, conservan más información y puede predecir homología más remotas.

En la tabla 2 podemos observar que cerca al 50% de las secuencias COS predichas en *Ipomoea batatas* (90 de 204) no presentan una anotación funcional luego de la búsqueda de similaridad usando Blast X, y es porque estos métodos de comparación de pares de secuencias presentan serias limitaciones para encontrar homólogos remotos, que son aquellos que comparten un mismo origen evolutivo pero que han divergido mucho y su identidad de secuencia está por debajo del 25% (Mount, 2003). Por ello para completar la anotación funcional hemos empleado un metaseruidor como el INTERPROSCAN, el cual integra en una sola búsqueda a muchas bases de datos de patrones, perfiles, dominios y motivos que permiten realizar la búsqueda de similaridad, pero restringida a residuos funcionales de la proteína (centros activos, zonas reguladoras), que han sido conservados durante la evolución por su importancia (Quevillon et al., 2005).

Otro método usado para la anotación funcional fue PSIBLAST, programa que primero realiza una búsqueda BLAST de similaridad de secuencia en una base de datos, y a partir de los resultados, construye un perfil o PSSM (position specific scoring matrix). Posteriormente, usando este perfil hace una nueva búsqueda en la base de datos, encontrando idealmente nuevas secuencias homólogas remotas, cuya información permite generar un nuevo perfil, que a su vez permite realizar otra búsqueda para predecir nuevas secuencias homólogas remotas (Altschul & Koonin, 1998).

En la figura 2 se observa que las 204 secuencias COS de *Ipomoea batatas* predichas presentan una distribución que cubre la mayor parte del genoma de *Arabidopsis*, observándose que en muy pocos casos los ESTs de las diferentes librerías de cDNA coinciden en algún punto del genoma, lo que se explica porque los ESTs provienen de tejidos bastante diferenciados no solo por

su función sino incluso por su estadio de desarrollo. Es posible inferir por ello que los ESTs que cubren una misma posición deben corresponder a genes constitutivos de la planta.

La predicción computacional de polimorfismos en las secuencias COS candidato se hace a fin de seleccionar las secuencias en las que con mayor probabilidad hay variaciones que puedan expresarse en la obtención de marcadores moleculares a partir de un estudio que involucre el uso de DNA genómico de diferentes variedades o poblaciones de *Ipomoea batatas*. Esta metodología puede ser utilizada en diferentes organismos, pero depende de la disponibilidad de secuencias en las bases de datos biológicas para el análisis. No obstante, con el incremento de los proyectos de secuenciación de genomas y el continuo y abundante depósito de información de secuencia (Paterson et al., 2000), esta posibilidad se incrementa, por lo que los métodos presentados se pueden constituir sin problemas en un proceso rutinario de trabajo en los laboratorios de Genética Molecular.

Nuestros resultados (tabla 4) muestran que a mayor número de secuencias que forman un *contig*, se obtiene mayor número de polimorfismos de tipo SNPs, obteniéndose en la mayoría de casos un mayor número de polimorfismos por transiciones que transversiones y deleciones respectivamente, lo que esta de acuerdo con la tendencia esperada para las probabilidades de estos tipos de mutación, y son estas secuencias las que podrían ser seleccionadas para el diseño de iniciadores de PCR, que conduzcan a los experimentos para la obtención de marcadores moleculares.

En los casos en los que las deleciones superan a los otros tipos de variación, probablemente se puede deber a que las secuencias del GenBank incorporadas al análisis de predicción de polimorfismos no provienen de genes ortólogos, sino parálogos con una similitud de secuencia bastante alta, y que no pudieron filtrarse previamente con los análisis de similitud, lo que puede ser reflejo de un origen evolutivo reciente. Estas últimas secuencias serían muy difíciles de utilizar para la obtención de marcadores moleculares, porque probablemente los iniciadores de PCR diseñados en ellas podrían coincidir en varias regiones del genoma, amplificando varios genes a la vez y con ello haciendo difícil la interpretación de los resultados experimentales.

Literatura citada

Altschul S.F. & E.V. Koonin. 1998. Iterated profile searches with PSI-BLAST--a tool for discovery in protein databases. *Trends Biochem Sci.* 23(11):444-447.

Altschul S.F., T.L. Madden, A.A. Schaffer, J. Zhang, Z. Zhang, W. Miller, & D.J. Lipman. 1997. Gapped BLAST and PSI-BLAST: a new generation of protein database search programs. *Nucleic Acids Res.* 25(17):3389-402.

Barker G, J. Batley, H. O'Sullivan, K.J. Edwards, D. Edwards. 2003. Redundancy based detection of sequence polymorphisms in expressed sequence tag data using autoSNP. *Bioinformatics.* 19(3):421-422.

Benson G. 1999. Tandem repeats finder: a program to analyze DNA sequences. *Nucleic Acids Research* 27(2): 573-580.

Claverie J-M. & C. Notredame. 2003. Similarity searches on Sequence Databases *Bioinformatics for Dummies*, New York, Wiley Publishing Inc., pp 279-215

Fulton T.M., R. Van der Hoeven, N.T. Eannetta, & S.D. Tanksley. 2002. Identification, analysis, and utilization of conserved ortholog set markers for comparative genomics in higher plants. *Plant Cell* 14: 1457-1467.

Gogarten J.P., & L. Olendzenski. 1999. Orthologs, paralogs and genome comparisons. *Curr Opin Genet Dev.* Dec;9(6):630-636.

Huang, X. & A. Madan,. 1999 CAP3: a DNA sequence assembly program *Genome Res.* 9, 868-877

Jewell E, A. Robinson, D. Savage, T. Erwin, C.G. Love, G.A. Lim, X. Li, J. Batley, G.C. Spangenberg & D. Edwards. 2006. SSRPrimer and SSR Taxonomy Tree: Biome SSR discovery. *Nucleic Acids Res.* 34:W656-659.

Kozik A & R. Michelmore. 2002. Computational approach to select the set of ESTs with a single BLAST hit to Arabidopsis genome. University of California at Davis http://cgpdb.ucdavis.edu/COS_Arabidopsis/ (acceso 20/02/07)

Kozik A, Kochetkova E, Michelmore R. 2002. GenomePixelizer--a visualization program for comparative genomics within and between species. *Bioinformatics.* 8(2):335-336.

Ku H.M., T. Vision, J. Liu, & S.D. Tanksley. 2000. Comparing sequenced segments of the tomato and Arabidopsis genomes: large-scale duplication followed by selective gene loss creates a network of synteny. *Proc Natl Acad Sci USA.* 97(16):9121-91216.

Mount D. 2003. *Bioinformatics: Sequence and Genome Analysis*. Cold Spring Harbour Laboratory Press, 10 Skyline Drive, Plainview, New York 11803-2500.

Paterson A.H., J.E. Bowers, M.D. Burow, X. Draye, C.G. Elsik, C.X. & et al.. 2000. Comparative genomics of plant chromosomes. *Plant Cell.* 12(9):1523-1540.

Pennisi E. 1998. A bonanza for plant genomics. *Science.* 282(5389):652-4.

Quevillon E, V. Silventoinen, S. Pillai, N. Harte, N. Mulder, R. Apweiler, & R. Lopez. 2005. InterProScan: protein domains identifier. *Nucleic Acids Res.* Jul 1(33): 116-120

Sonnhammer E.L. & E.V. Koonin. 2002. Orthology, paralogy and proposed classification for paralog subtypes. *Trends Genet.* 18(12):619-620.

Stajich J.E., D. Block, K. Boulez, S.E. Brenner, S.A. Chervitz, C. Dagdigan & et al. 2002. The Bioperl toolkit: Perl modules for the life sciences. *Genome Res.* 12(10):1611-1618.

Zheng X.H., F. Lu, Z.Y. Wang, F. Zhong, J. Hoover, & R. Mural. 2005. Using shared genomic synteny and shared protein functions to enhance the identification of orthologous gene pairs. *Bioinformatics.* 21(6):703-710

