



**UNIVERSIDAD NACIONAL AUTÓNOMA
DE MÉXICO**

**FACULTAD DE ESTUDIOS SUPERIORES
IZTACALA**

**"ANÁLISIS IN SILICO DEL TRANSCRIPTOMAS
DEL EPITELIO CERVICAL NORMAL"**

T E S I S

QUE PARA OBTENER EL TITULO DE:
LICENCIADO EN BIOLOGÍA

P R E S E N T A :

HUGO ARREOLA DE LA CRUZ

ASESOR:
Dr. MAURICIO SALCEDO VARGA



MÉXICO, D. F.

2004



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.

AGRADECIMIENTOS

AmisPadres, porsuamortanincondicional,yporbrindarmesuapoyo y las herramientas necesarias para la realización de esta meta en mi vida, GRACIAS.

Amishermanos,ServandoyEloisa;porsuamoryapoyo,yaqueenlos momentos más difíciles siempre han estado conmigo.

Ati Irina, por ser la mujer que es, ya que es un pilar importante en mi vida, ya que siempre he tenido tu apoyo para seguir adelante, esperando toda mi vida contar con el.

AIDr.MauricioSalcedo,porsu gran apoyo y comprensión, no me queda mas que agradecerle por la gran persona que es en todo sentido, GRACIAS.

Ati Carlos, por esas jornadas en el laboratorio, y por ser una gran persona.

Amis grandes amigos de la Universidad (Alberto, Alya, Elena, Erika, Gerardo, Miran, Mata y Sandra), por esos grandes momentos que vivimos, y por soportarme. Espero seguir contando con ustedes.

A los chavos del laboratorio, por formar el grupo que somos, y por ser tan ameno el trabajo.

A la Familia Reyes González, por ser quienes son conmigo, y por soportarme.

ÍNDICE

Introducción.....	1
Características generales del Cuello Uterino.....	1
Biología de la infección del Virus de Papiloma Humano.....	6
Antecedentes.....	7
Desarrollo del Análisis en Serie de Expresión Génica (SAGE).....	11
Justificación.....	16
Objetivo General.....	17
Objetivos Particulares.....	17
Material y Métodos.....	18
Función Biológica.....	20
Esquema General del Proceso de Substracción <i>in silico</i>	26
Resultados y Discusión.....	27

Representación esquemática de la función biológica de los genes de la Biblioteca de Expresión de Cervix Normal.....	31
Caracterización parcial de la Biblioteca de Expresión de Cervix Normal.....	3
Literatura Citada.....	38

RESUMEN

El Cáncer Cérvico -uterino(CaCu) se ha visto fuertemente asociado a la infección con Virus de Papiloma Humano(VPH), un factor sexualmente transmisible. Datos de la Organización Mundial de la Salud (OMS) muestran que la frecuencia anual de mortalidad por CaCu, es de 237,000 casos. En México, de acuerdo con la Secretaría de Salud, el CaCu es la neoplasia maligna con mayor incidencia(32.5%) entre la población femenina. Para entender los cambios moleculares que sufre un tejido normal, con respecto a su contraparte transformada, primeramente se necesita conocer cómo está organizado el tejido normal; es en este sentido que por medio del Análisis en Serie de Expresión Génica (SAGE), nos permite evaluar transcriptomas de una manera cuantitativa. Esta poderosa herramienta ha sido usada básicamente para comparar tejidos tumorales, así como de su contraparte normal. En este trabajo se utilizó la biblioteca de expresión de Cervix Normal, para su caracterización de manera preliminar por medio del análisis *in silico*, ya que no hay nada descrito en Cervix en términos de expresión diferencial.

INTRODUCCIÓN

Características Generales del Cuello del Útero Normal.

El Cervix o Cuello uterino, es la parte inferior del útero que ocupa aproximadamente la tercera parte de este órgano. Constituye el canal de comunicación del cuerpo uterino con la vagina de la mujer. El conducto cervical mide aproximadamente 2.5 a 3.0 cm y mantiene la secreción mucocervical de manera continua¹ (Fig. 1).

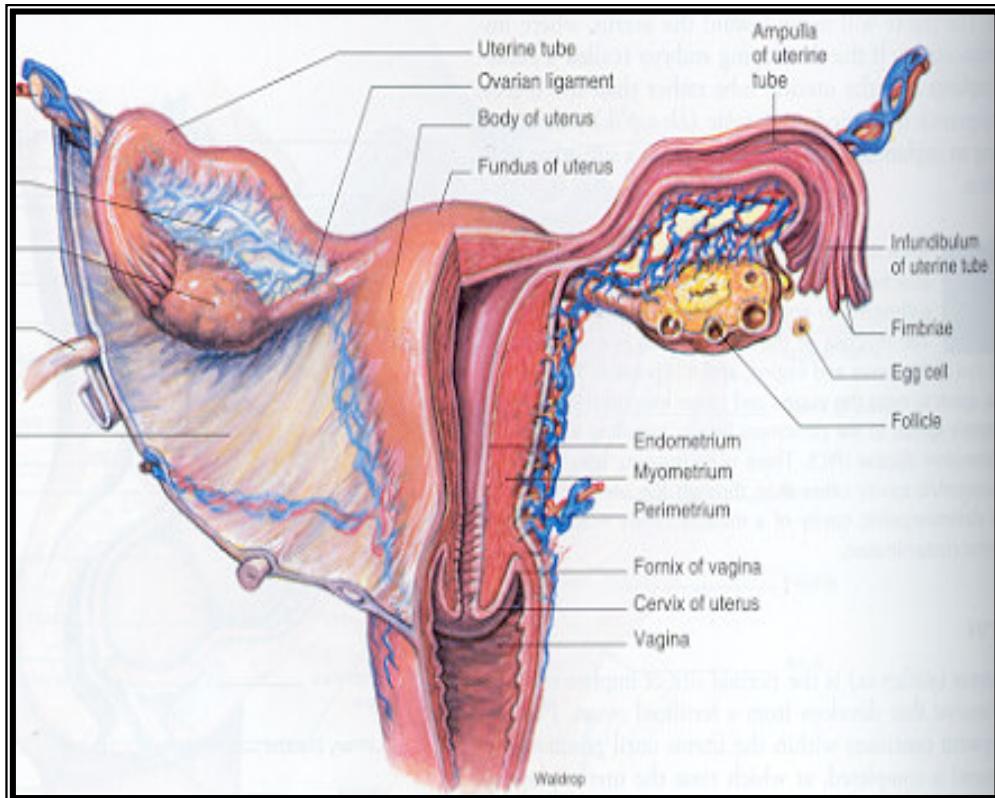


Fig. 1. Localización anatómica del Cervix.

La superficie más expuesta del cérvix queda al lado de la vagina y es conocida como exocervix, y la porción del cérvix en relación con el canal endocervical es conocida como el endocervix. El exocervix está

revestido de un epitelio escamoso estratificado que tiene una función; en primera, separa y acumula cantidades variables de glicógeno en su estrato superior en respuesta a la circulación de estrógeno, especialmente estradiol; y, en segundo lugar, es un tejido protector debido a su superficie cornificada.

El epitelio escamoso cervical está dividido según Dierksen en 5 estratos:

- Estrato de células basales : son células pequeñas, cilíndricas, con escaso citoplasma y núcleo relativamente grande de forma oval con cromatina densa; estas células son usualmente inactivas mitóticamente.
- Estrato de células parabasales o espinosas: son células poliédricas con núcleos bastante grandes y puentes intercelulares evidentes, son más largas que las basales por su incremento de citoplasma, su núcleo tiene ligeramente menos cromatina y la actividad mitótica está presente. En ocasiones estas células pueden ser vacuoladas.
- Estrato de la zona media : las células son más grandes, planas, con citoplasma abundante, muy vacuoladas con abundante glucógeno y cantidades variables de inclusiones granulares, estas células son conocidas como células intermedias.
- Estrato granulosum: es constante e irreconocible, consta de una banda estrecha de células planas que tienen intensamente y contiene gránulos de queratohialina.

- Estrato superficial: consta de células alargadas y aplanadas con núcleos pequeños redondos y picnóticos y un citoplasma abundante² (Fig.2).

El epitelio endocervical es monoestratificado cilíndrico y mucho más alto que el epitelio del endometrio. El endocervix está compuesto por un solo estrato de epitelio secretor de mucina; sus núcleos son compactos,

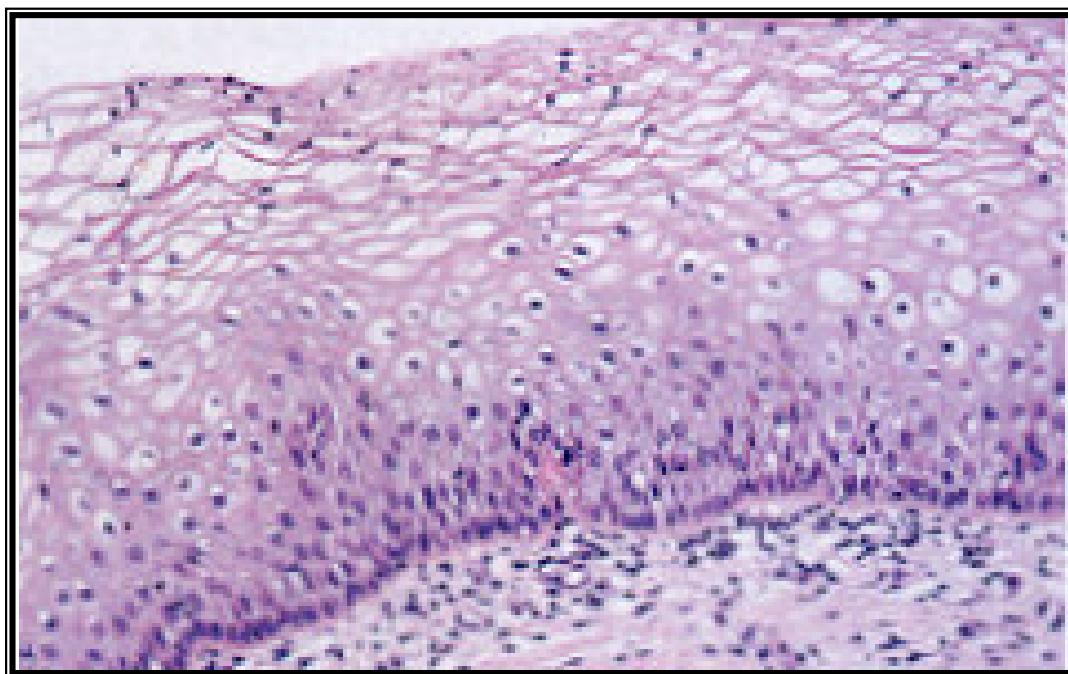


Fig. 2. Epitelio escamoso cervical.

pequeños y bien estilizados y se sitúan en el polo basal.
de 20 a 35 micras de altura y de 5 a 9 micras de anchura.
segregan mucina. Por su forma cilíndrica y alargada se le ha llamado
también células senempalizadas¹.

Las células más idénticas
Estas células

La unión del epitelio cilíndrico con el epitelio escamoso del exocervix es brusca, encontrándose los dos tipos de epitelio totalmente diferenciados en un punto definido, que se conoce con el nombre de unión

escamocilíndrica. Aunque esto no se observa, en todos los casos, en la mayoría de ellos existe una zona transicional, que separa los dos epitelios. Estos dos tipos no son constantes en la totalidad de la circunferencia del conducto cervical². Esta unión escamocilíndrica es donde se presentan la mayoría de las enfermedades epiteliales del cérvix en la mujer, como es el caso del Cáncer Cérvico -uterino (CaCu) o cáncer del cuello de la matriz, el cual representa uno de los mayores problemas de salud en la mujer en el ámbito mundial. Datos de la Organización Mundial de la Salud (OMS) muestran que la frecuencia anual de mortalidad por CaCu, es de 237,000 casos³. En México, de acuerdo con la Secretaría de Salud, el CaCu es la neoplasia maligna con mayor incidencia (32.5%) entre la población femenina⁴.

Asimismo, uno de los principales agentes etiológicos asociados al desarrollo del CaCu es la infección por Virus de Papiloma Humano (VPH), un factor sexualmente transmisible. Estudios recientes, utilizando metodologías muy sensibles de detección, han confirmado una positividad a VPH en el 99.7% de los casos de CaCu⁵. El VPH induce la transformación celular por medio de la inhibición de los mecanismos de regulación del ciclo celular, modificando el perfil global de expresión genética, que traerá como consecuencia alteraciones del fenotipo celular.

Los Virus del Papiloma Humano pertenecen a la familia Papillomaviridae, y comprenden alrededor de 100 tipos distintos⁶. Son epitelio trópicos, con una doble cadena de DNA circular en vuelo en una cubierta proteica llamada cápside. Se nombrase componen de dos grupos funcionales de marcos de lectura abiertos, llamados tempranos (E), y tardíos (L); están separados por una Región Larga de Control (LCR), que es necesaria para la replicación viral normal y el control de la replicación de genes⁷. En la región temprana se encuentran genes que participan en la

replicación viral y la inmortalización celular, por ejemplo E6 y E7. La principal función biológica de E6 hasta la fecha parece ser la inactivación de la proteína supresora del tumor p53. Por su parte, E7 escapaz de formar complejos con varias proteínas celulares, incluyendo a la proteína supresora de tumor retinoblastoma (pRb). Finalmente, los genes de la región tardía codifican para proteínas de los capsómeros (Fig. 3). En general, los tumores sufren una continua acumulación de cambios genéticos y epigenéticos que les permiten escapar de los controles de regulación celular y ambiental.⁸

Se han desarrollado diferentes metodologías para caracterizar el perfil de expresión global en una célula o tejido e identificar los genes involucrados en un proceso de desarrollo, en respuestas celulares a estímulos físicos o químicos, o genes involucrados en procesos oncogénicos en un tipo de neoplasia determinada.¹⁰

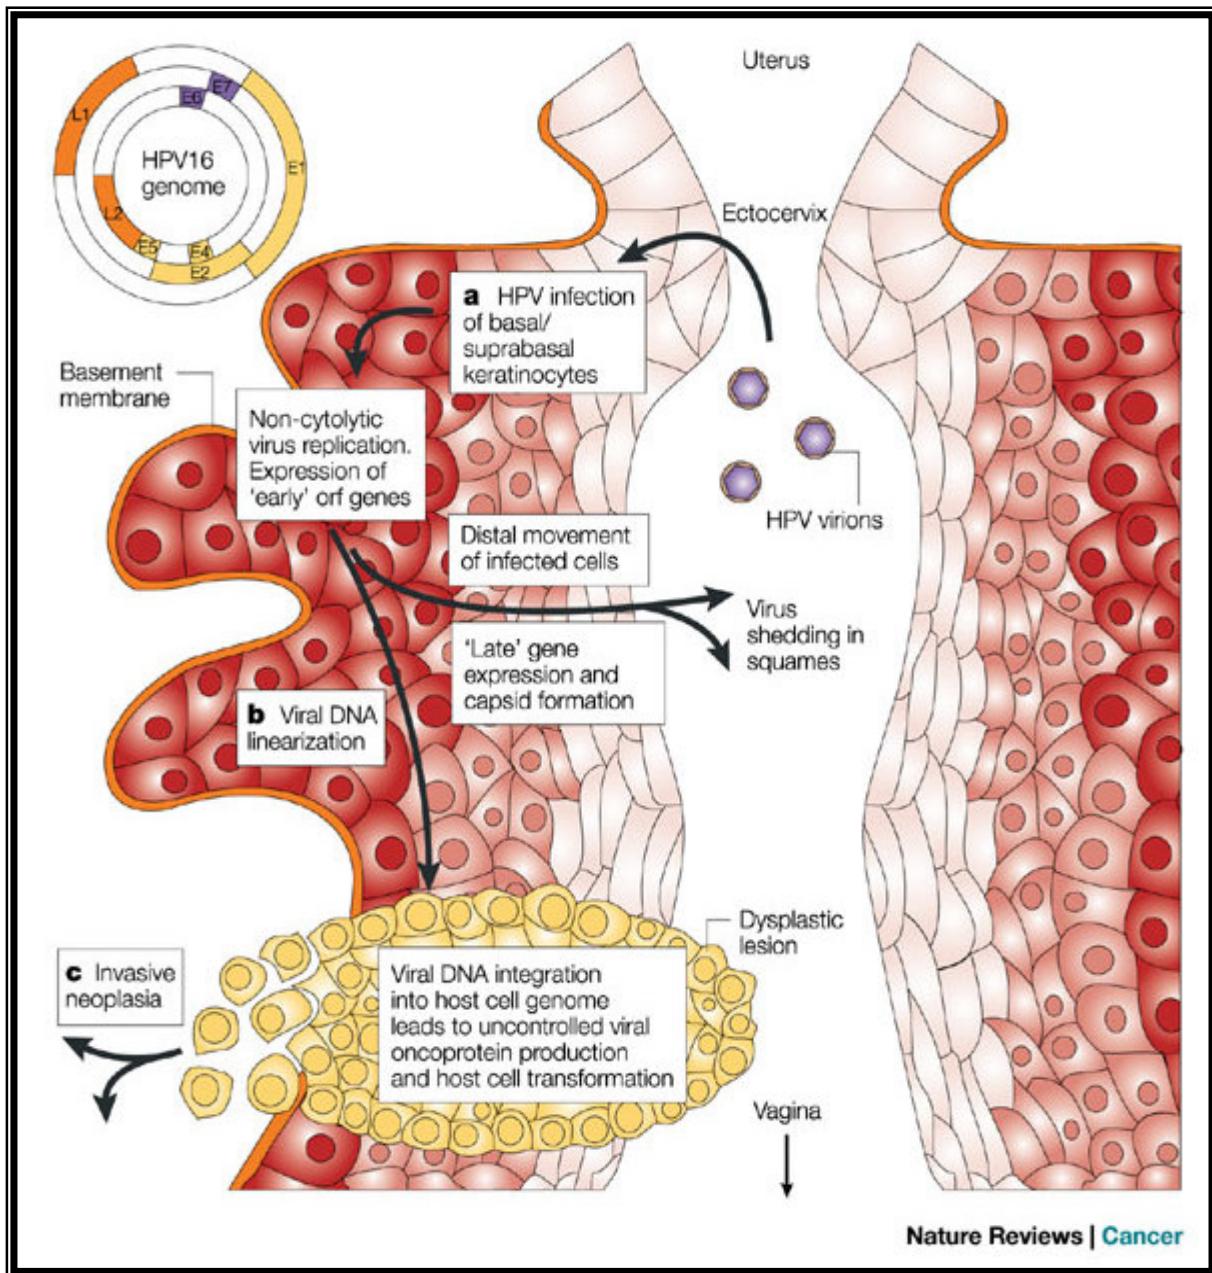


Fig. 3. Esquema que representa la biología de la infección de VPH⁹.

ANTECEDENTES

Entre los métodos más empleados para clonar genes expresados diferencialmente, se encuentran el análisis representativo de diferencias (RDA), despliegue diferencial (DD), reacción en cadena de la polimerasa iniciada arbitrariamente (RAP -PCR), e hibridación subtractiva (SH). Básicamente, todos estos métodos están diseñados para amplificar y aislar secuencias de ácidos nucléicos presentes en una muestra y ausentes o expresados en un nivel diferente en otra muestra empleada como comparativo. Estas técnicas permiten la detección de cambios en la expresión de RNAs mensajero por medio de un enriquecimiento selectivo sin ningún conocimiento previo de la secuencia de genes específicos¹¹. Sin embargo, no pueden detectar transcritos expresados a bajos niveles, además los pasos sucesivos de substracción y amplificación hacen posible la aparición de falsos positivos¹². Se han empleado otros métodos como las hileras de cDNA o oligonucleótidos (Microarrays); aún cuando puedan comparar miles de genes, están limitados por el uso de transcritos previamente caracterizados y/o de secuencias conocidas.

En este sentido, el análisis en serie de la expresión génica (SAGE), que es una plataforma metodológica que involucra herramientas de biología molecular como de bioinformática, nos permite un análisis amplio y cuantitativo del perfil de expresión celular. Gracias a esta herramienta se conoce que un grupo de genes (alrededor de 40) se sobreexpresan en diferentes neoplasias (por ejemplo, carcinoma colorectal, mama, melanoma, etc.), es decir, el transcriptoma mínimo.

Con esta plataforma de análisis global, los transcritos (RNAm) son convertidos a cDNA, después digeridos en fragmentos pequeños o

etiquetas (tags de 10 -14 pb) por enzimas de restricción específicas SAGE está basado en los principios: la representación de los transcritos expresados por secuencias cortas de cDNA o etiquetas y la concatenación de estas etiquetas para su clonación y análisis mediante la secuenciación. Apartir del borrador del genoma humano ¹³, se sabe que éste consta de 30,000 a 40,000 genes; una secuencia de 10 pares de bases podría identificar más de 1×10^6 transcritos diferentes (4^{10}). Por lo que el tamaño de estos tags es suficiente para discriminar todos los transcritos presentes de un acélula en un momento dado ¹⁴. Con esta plataforma metodológica se pueden detectar y cuantificar simultáneamente los niveles de expresión génica de una célula en un momento dado; posee la sensibilidad de detectar genes expresados en bajos niveles, así como identificar genes nuevos, debido a que en análisis se desarrolla utilizando la totalidad de los mRNA de la muestra a estudiar, es decir SAGE es un sistema de análisis abierto, a diferencia de otras herramientas como son las microhileras de tejidos en los cuales se deben tener un previo conocimiento de los genes objeto de estudio. En suma, SAGE puede definir la historia celular en función de los niveles de expresión génica de un linaje específico o de una entidad patológica dada ¹⁵. Esta herramienta ha empleado en la comprensión del proceso que lleva una célula normal a su contraparte neoplásica, principalmente en tres aspectos:

- El análisis de diferencias entre los patrones de expresión de distintos tipos de neoplasias y su contraparte normal.
- Identificación de genes aún no descritos que pueden jugar un papel en el desarrollo de alguna neoplasia.
- Identificación de genes regulados por oncogenes y genes supresores de tumor.

Este tipo de estudio nos permite comprender cuáles son las vías de regulación en los procesos involucrados en la tumorigénesis; asimismo, nos permite la identificación de nuevos marcadores de pronóstico y diagnóstico. En los estudios realizados por medio de esta plataforma, se ha encontrado concordancia en los resultados, validando de esta forma la utilidad del gen identificado como posible marcador de pronóstico y/o diagnóstico¹⁶. Un ejemplo de esto, empleando SAGE, es el estudio que valida o reafirma el gran potencial del análisis de Bibliotecas SAGE que fue la identificación de un nuevo miembro perteneciente a la familia de los antígenos de melanoma (MAGE), denominado MAGE -E1 entre tres variantes producidas por splicing alternativo (MAGE -E1a, MAGE -E1b y MAGE -E1c). MAGE-E1a y MAGE -1b fueron expresados específicamente en células de glioma¹⁷. Con SAGE se pudo identificar las diferencias entre tejido neoplásico y su contraparte normal; en cáncer de mama se identificó una etiqueta que no se relacionaba con ningún genóEST (fragmento de secuencia expresado), y que se presentó con un alto número de copias en las librerías de células epiteliales normales; a diferencia de las bibliotecas desarrolladas a partir de carcinoma ductal *in situ* o sus metástasis, en donde se observó dichotogía (que se dio el nombre de HIN -1a este nuevo gen)¹⁸. Al aumentar el número de casos analizados específicamente para la expresión de HIN -1, se observó en sólo 21% de los tejidos neoplásicos estudiados. Al clonar y expresar el cDNA de HIN -1 se observó que es una proteína secretada que regula negativamente el crecimiento celular de líneas celulares derivadas de cáncer de mama¹⁹. La identificación de diferencias en tejidos neoplásicos y su contraparte normal a nivel molecular, abre importantes expectativas en cuanto a los mecanismos que propician el desarrollo de un cáncer. Identificar estos actores específicos encadenados nos permitirá tener las herramientas necesarias para pronosticar y diagnosticar eficientemente,

sino que por otra parte podremos comprender mejor el fenómeno analizado a diferencia de hace algunos años.

Encuentro la identificación de genes regulados por genes que modulan el perfil de expresión como *p53*, el grupo de Bert Vogelstein induciendo la función de *p53* en una línea celular con *p53* deletado, encontraron que 34 tags diferentes en ensayos de expresión, de los cuales sólo tres han sido previamente identificados como genes regulados por *p53*²⁰.

SAGE ha sido propuesto como una herramienta analítica estratégica en el Proyecto de la Anatomía del Cáncer (CGAP), y se ha creado una base de datos con tags producidos por esta estrategia. Al fecha hay más de tres millones de tags de 8 diferentes librerías derivados de 19 tejidos, tanto normales como tumorales (www.ncbi.nlm.nih.gov/SAGE). El análisis de estos datos ha arrojado algunos patrones interesantes; en primer lugar, células cancerosas y sus contrapartes normales presentan un patrón de expresión celular muy similar, de hecho alrededor de 40 genes se expresan en niveles elevados en todos los tejidos cancerosos, no así en los tejidos normales; esto podría sugerir que estos genes estén involucrados en el proceso de tumorigénesis y los señala como marcadores moleculares como blancos para estrategias terapéuticas.

Por otra parte, se observó de manera obvia que en los tejidos neoplásicos usualmente hay un aumento en la expresión de genes asociados con la proliferación y supervivencia y una disminución en genes involucrados en diferenciación. Además, se encontró que cerca de 1,000 transcritos se expresaban en todos los tejidos estudiados, los cuales representan el transcriptoma mínimo; es decir, aquellos genes cuya expresión es necesaria para mantener la maquinaria celular funcional^{21,22}.

DESARROLLO DEL ANÁLISIS EN SERIE DE EXPRESIÓN GÉNICA (SAGE)

- Obtención y purificación de RNA total (5 µg) apartir de material biológico.
- Por medio de partículas paramagnéticas acopladas a oligo (dT) biotinilado, se aísla el mRNA.
- Para la síntesis de la primera cadena de cDNA se utiliza la enzima transcriptasa Reversa SuperScript; para la síntesis de la segunda cadena de cDNA se realiza una digestión parcial con la enzima RNase H, y la síntesis se lleva a cabo con las enzimas DNA ligasa y la DNA polimerasa.
- Se efectúa una digestión con la enzima Nla III, que reconoce la secuencia palindrómica CATG, por lo que genera extremos cohesivos, y corta aproximadamente cada 25 pares de bases.
- Una vez realizada la digestión con Nla III, se divide la población de cDNA en dos fracciones (A y B), esto con la finalidad de ligarlos a adaptadores sintéticos (aproximadamente de 40 pb cada uno), que tienen extremos cohesivos complementarios a la secuencia CATG. Posteriormente para generar los tags; al final de la secuencia del adaptador se encuentra un sitio de reconocimiento para la enzima BsmF I, que es una enzima de tipo II, por lo que su sitio de reconocimiento se encuentra dejado desusitio de corte; para esta enzima hasta 14 pb, y de esta forma se forman los tags.

- Una vez que fueron ligados los tags a los adaptadores, los siguientes unir los ditags, es decir, tag -tag, por lo que los adaptadores tienen una modificación en su extremo 3', un grupo amino unido por medio de un enlace covalente, por lo que no se separa del adaptador con adaptador, de esta forma no se asegura que en la etapa de ligación esté el tag.
- Se hace la amplificación de los ditags por medio de reacciones de PCR, que para conocer el número óptimo de reacciones se intenta tener el suficiente número de ditags, se hace una titulación con diferentes diluciones del producto de PCR, utilizando como control DNA de concentración conocida, ya que en los subsecuentes pasos de purificación se pierde una cantidad considerable de material.
- Después de realizadas las reacciones de PCR, las reacciones se concentran en un solo tubo, el DNA presente se purifica empleando Fenol/Cloroformo y se precipitan por medio de Acetato de Amonio. Posteriormente las muestras son sujetas a un gel preparativo de poliacrilamida al 8%, y se cortan las bandas correspondientes a los ditags, que son las de 100 bp aproximadamente, las otras bandas presentes corresponden a los adaptadores y a digestiones incompletas. Finalmente, el DNA correspondiente a los ditags es cortado y elulado.
- Nuevamente se hace una digestión con la enzima NlaIII, para liberar los ditags de los adaptadores, ya que los adaptadores tienen un extremo cohesivo complementario a NlaIII. Los ditags liberados se corren en un gel preparativo de poliacrilamida al 12% para comprobar la banda correspondiente a los ditags, para su posterior concatamerización.

- Por medio de la enzima T4 DNA ligasa fue posible concatenar los ditags de 25pb. Cada concatámero contiene de 30 a 50 etiquetas. Para tener diferentes poblaciones de los concatámeros, se corrió un gel preparativo de poliacrilamida 8%, de donde se seleccionaron tres regiones; de 30 a 50 pb, de 50 a 80 pb y de 80 a 100 pb. Cada región se clona en un vector de expresión (pZero).
- Posteriormente se electroporó una cepa de *E. coli* TOP10.
 - Las bacterias recombinantes se crecen en placas con 50 μg/ml de Zeocina. Las colonias recidas se pican y se analizan por medio de PCR empleando iniciadores específicos para PUCM13, aquellas colonias con insertos mayores a 50 pb, (lo que equivale a un inserto mayor a 25 tags) se purifican y se meten en una reacción de marcaje con Big Dye (Perkin Elmer) y analizadas en un secuenciador de Applied Biosystems modelo 310. Los resultados obtenidos servirán para alimentar el software de análisis SAGE 200 (Johns Hopkins University); que reconoce los signos de puntuación CATG generados por NlaIII, extrayendo la secuencia de cada tag. De esta manera, se produce una base de datos en Excel que muestra las secuencias de 10 pb que corresponde a cada tag (Fig.4).

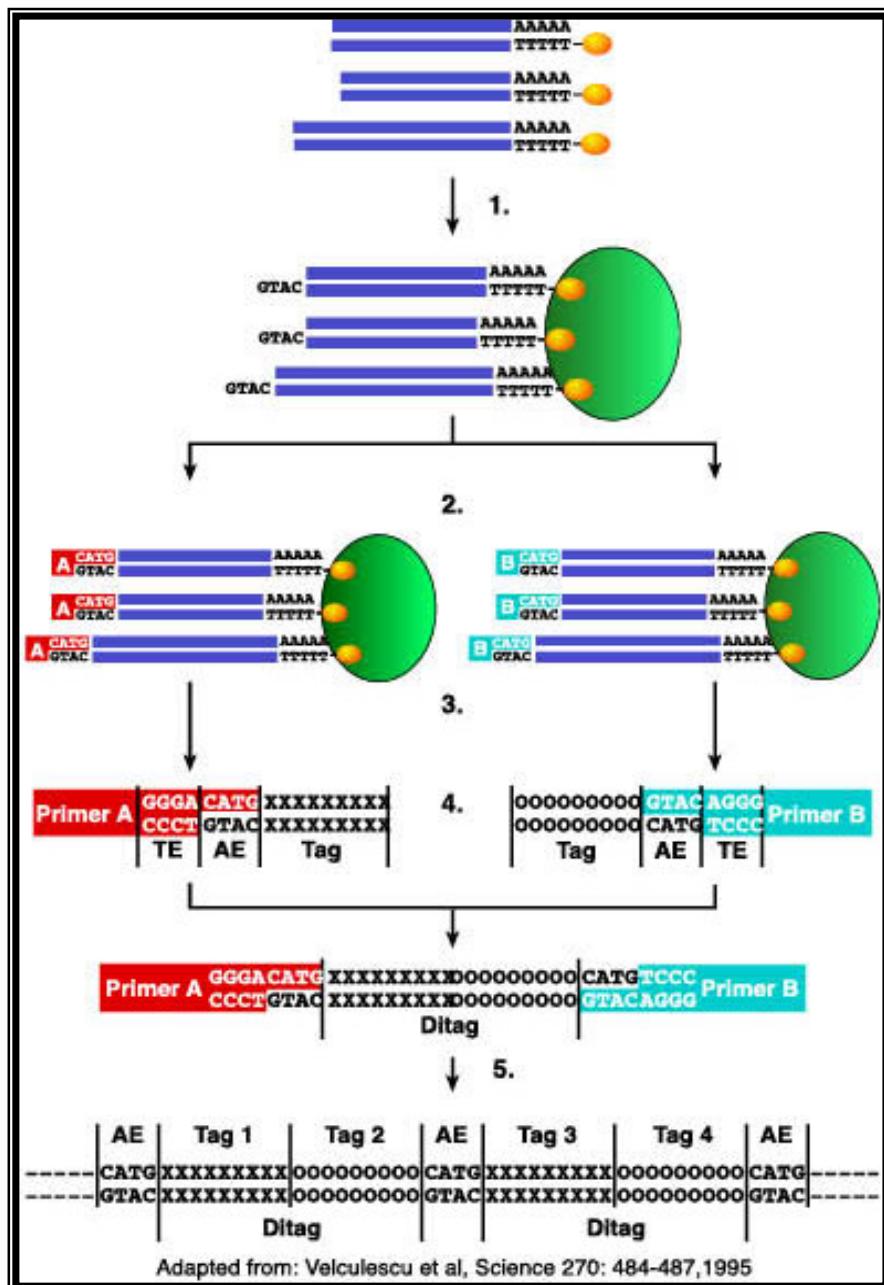


Fig. 4. Proceso experimental del Análisis en Serie de Expresión Génica (SAGE).

La gran cantidad de datos de secuencias disponibles en las bases de datos públicas plantea nuevos retos para los investigadores. En la era post-Genómica, la interpretación de los datos y el desarrollo de modelos que informen del fenómeno biológico específico constituye una prioridad. Hoy en día, a raíz de la gran cantidad de datos generados a partir del proyecto del Genoma Humano, la interpretación de esos datos en términos biológicos es de gran importancia; esa es la función fundamental en la elaboración de los modelos bioinformáticos que juegan un papel fundamental en la caracterización matemática que puede dar una interpretación biológica de esa gran cantidad de datos. En este contexto, es de gran importancia la caracterización de los transcriptomas de un tejido normal y de su contraparte transformada, así como identificar los genes que se están expresando de manera diferencial²³.

A la fecha hay una cantidad limitada de análisis *in silico* de bibliotecas de expresión SAGE que han arrojado resultados muy interesantes en cuanto a la identificación de genes específicos; existe, por ejemplo, un estudio en el cual se describen tres nuevos genes expresados exclusivamente en próstata por medio de la substracción *in silico* de bibliotecas de EST's²⁴. Diez candidatos a genes específicos de granulocitos han sido identificados por análisis extensivo de secuencias de bibliotecas de cDNA derivadas de granulocitos y de otros once tejidos, es decir, una línea celular de hepatocitos, hígado fetal, hígado de adulto, grasa visceral, pulmón, mucosa colónica, keratinocitos, cornea y retina²⁵.

JUSTIFICACIÓN

Hasta el momento no hay nada descrito en Cervix en términos de expresión diferencial, la comparación de esta biblioteca con respecto de otras bibliotecas de expresión SAGE publicadas en la red, permitirá distinguir genes específicos para este tejido.

Para entender los cambios moleculares que sufre un tejido normal, con respecto a su contraparte transformada, primeramente se necesita conocer cómo está organizado el tejido normal, para poder entender los cambios que originan el fenotipo transformado y la caracterización de perfiles globales de expresión que pueden ayudar a explicar procesos biológicos importantes en las células normales. Este tipo de estudios ayuda a comprender las bases moleculares de los fenotipos ya caracterizados, y así prevenir o detener el desarrollo del CaCu.

OBJETIVO GENERAL

Caracterizar por análisis *in silico* el perfil de expresión global de la biblioteca de expresión SAGE del epitelio cervical normal.

OBJETIVOS PARTICULARES:

- Caracterizar de manera preliminar *in silico* a nivel funcional, la biblioteca de expresión del epitelio cervical normal.
- Mapear físicamente en su posición cromosómica los genes expresados.

MATERIAL Y METODOS

La biblioteca de expresión de Cervix uterina normal, fue elaborada en el Laboratorio de Oncología Genómica, a cargo del Dr. Mauricio Salcedo Vargas, de la Unidad de Investigación en Enfermedades Oncológicas, Hospital de Oncología, Centro Médico Nacional Siglo XXI, IMSS, en colaboración con el Dr. Gregory J. Riggins, Director del proyecto de la Anatomía de la Célula Cancerosa del Centro Nacional de Biotecnología (NCBI) de los Estados Unidos. La biblioteca de expresión se encuentra disponible en un sitio público en la red del NIH (Instituto Nacional de la Salud); SAGEmap (<http://www.ncbi.nlm.nih.gov/SAGE/>), en el cual se encuentra una gran cantidad de bibliotecas de expresión tanto tumorales como normales. De cada biblioteca se da una breve descripción del origen del tejido, título de la biblioteca de expresión, la cuenta total de tags, el nombre de los autores, fecha en que se publicó, entre otros; de una serie de herramientas para el análisis de las bibliotecas (Fig.5).

Sample GSM2455

Query DataSets for GSM2455

Status	Public on Oct 3 2002
Title	SAGE_cervix_normal_B_1
Type	sage
Anchor	Nlall
Organism	Homo sapiens
Target source	normal exocervix
Tag count	30418
Description	Uterine cervix normal SAGE, CGAP non-normalized SAGE library, bulk method , HPV negative
Keyword	uterine cervix
Author	Perez-Plasencia C, Riggins G, Arreola H, Hidalgo A, Salcedo M
Submission date	Oct 3 2002
Submitter name	Perez-Plasencia, Carlos
Submitter email	car_plas@yahoo.com
Submitter institute	Mexican Institute for Social Security
Submitter laboratory	Oncology Genomics
Submitter department	UIIMEO
Submitter address	Cuahtemoc 300
Submitter city	Mexico, D.F. 06720 Mexico
Submitter phone	+56.27.69.00 ext 4323

Aceptando Pop-ups ▾ 0

Fig. 5. Descripción de la biblioteca de expresión.

Una vez que la biblioteca de expresión se descargó de la red, los datos se cargarán al programa de MS Access con la lista de actualizaciones de un gen para que de esta manera se pudiera tener la lista de los genes totales presentes en la biblioteca así como el nombre del gen, función y su número de identificación para sus análisis en las bases de datos en internet. Una vez realizada la consulta en el programa de MS Access, la tabla resultante se exportó al programa de Excel, que contiene los datos de los tags, nombre de los genes, así como su función de toda la biblioteca de expresión, etc.

FUNCIÓN BIOLÓGICA

Para tener una relación de la biblioteca de expresión en cuanto a su función biológica, se utilizó la herramienta bioinformática (FATIGO) en la red (<http://fatigo.bioinfo.cnio.es>) (Fig. 6). Inicialmente esta herramienta fue desarrollada para permitir la explotación de datos resultantes de microarreglos, con el objeto de identificar las rutas metabólicas que se alteran entre dos o más estadios diferentes. Además, esta herramienta nos permite el análisis de una gran cantidad de datos (genes), en cuanto a su proceso biológico, definiendo el organismo o la base de datos a analizar. Asimismo, FATIGO se puede emplear para comparar listas de genes y encontrar cambios diferencialmente representados entre ellas.

Bioinformatics Unit - CNIO

Data mining with Gene Ontology [Help](#)

1. Search GO terms for a list of genes
2. Compare two lists of genes

Search GO terms for a list of genes

Define organism or database to analyse Choose Ontology Choose Level

----- Biological process 3

Search GO terms for this list of genes

or download list from file [Examinar...](#) [Compare](#)

Select if you want a tree representation

Show results arranged by: Percentages are calculated with respect to: Only genes with GO annotated

FatiGO can also be used to compare two lists of genes and find GO terms differentially represented between them

Fig. 6. Página web (Gene Ontology), herramienta utilizada para el análisis de una gran cantidad de datos (genes), en términos de su proceso biológico.

Para poder comparar los resultados con bases de datos de EST's, se realizó labús queda en la fuente de SOURCE; la cual fue desarrollada por la Universidad de Stanford (<http://source.stanford.edu/cgi-bin/sourceSearch>)²⁶, y así corroborar los resultados anteriores de Gene Ontology (Fig. 7). Esta herramienta unificada, compila y colecta datos procedentes de una gran variedad de bases de datos científicas, encapsulando la biología molecular de miles de genes derivados de Homo Sapiens, Ratus Norvertus, entre otros organismos. Asimismo, permite generar tablas donde el usuario programa la obtención de los datos requeridos de algún gen ó genes; por ejemplo, datos de expresión, papel biológico, etc.

SOURCE is a unification tool which dynamically collects and compiles data from many scientific databases, and thereby attempts to encapsulate the genetics and molecular biology of genes from the genomes of *Homo sapiens*, *Mus musculus*, *Rattus norvegicus* into easy to navigate GeneReports.

The mission of SOURCE is to provide a unique scientific resource that pools publicly available data commonly sought after for any clone, GenBank accession number, or gene. SOURCE is specifically designed to facilitate the analysis of large sets of data that biologists can now produce using genome-scale experimental approaches.

Five Most Recent Additions:

- Read the SOURCE paper at [NAR](#) or as a [PDF](#)
- SOURCE is now available at <http://source.stanford.edu>
- Retrieval of upstream genomic sequences from human GeneReports
- Link to UCSC Genome Browser from human GeneReports
- Representative protein accessions available in BatchSource

Choose organism: Homo sapiens

Choose search option: UniGene ClusterID

Enter a search term:

Use a wildcard character (*) at the end and/or beginning of the term to broaden your search.

Choose type of information to display:

GeneReport: Gene Information (limited to those in UniGene)
 CloneReport: cDNA Clone Information (limited to those in dbEST)

Submit | Reset Form

Batch SOURCE: [Extract data for multiple genes at once](#)

Aceptando Pop-ups ▾ | 0

Fig. 7. Sitio web (SOURCE) para la búsqueda por gen o lista de genes en cuanto a su función biológica, biología molecular, etc.

Por otra parte, se realizó la distribución de los genes que comprende la biblioteca de expresión de los largos de los cromosomas, es decir, los genes expresados a lo largo de cada uno de los cromosomas, y de esta manera obtener una gráfica de su distribución, la cual se realizó con otro programa, el DeltaGraphic. Primeramente se obtuvo el esquema de los cromosomas, así como el tamaño (en pares de bases) de cada uno. Esto se pudo realizar gracias a otros sitios web (<http://genome.ucsc.edu/cgi-bin/hgGateway>) (Fig. 8), de donde se extrajo la información requerida. En el programa se cargó la longitud de cada uno de los cromosomas, así como el nucleótido en que inicia y termina cada gen. Esto trajo como resultado la representación esquemática de la biblioteca de expresión de los largos de los cromosomas.

Home · Genome Browser · Blat · Table Browser · FAQ · Help

Human Genome Browser Gateway

The UCSC Genome Browser was created by the [Genome Bioinformatics Group of UC Santa Cruz](#).
Software Copyright (c) The Regents of the University of California. All rights reserved.

genome	assembly	position	image width
Human	July 2003	chr4:56,214,201-56,291,736	620

[Click here to reset](#) the browser user interface settings to their defaults.

[Add Your Own Custom Tracks](#)

About the *Homo sapiens* assembly

The July 2003 human reference sequence (UCSC version hg16) is based on NCBI Build 34 and was produced by the International Human Genome Sequencing Consortium. The sequence covers about 99 percent of the gene-containing regions in the genome, and has been sequenced to an accuracy of 99.99 percent. Of note in this release is the addition of the pseudoautosomal regions of the Y chromosome. This sequence was taken from the corresponding regions in the X chromosome and is an exact duplication of that sequence.

There are 2,843,433,602 finished sequenced bases in the ordered and oriented portion of the assembly, which is an increase of 0.4 percent, or approximately 11 Mb, over the Build 33 assembly. The reference sequence is considered to be "finished", a technical term indicating that the sequence is highly accurate (with fewer than one error per 10,000 bases) and highly contiguous (with the only remaining gaps corresponding to regions whose sequence cannot be reliably resolved with current technology). Future work on the reference sequence will focus on improving accuracy and reducing gaps in the sequence.

Some sequence joins between adjacent clones in this assembly could not be computationally validated because the clones originated from different haplotypes and contained polymorphisms in the overlapping sequence, or the overlap was too small to be reliable. In these instances, the sequencing center responsible for the particular chromosome has provided data to support the join in the form of an electronic certificate. These certificates may be reviewed through the link below.

Bulk downloads of the sequence and annotation data are available via the Genome Browser [FTP server](#) or the [Downloads](#) page. The hg16 annotation tracks were generated by UCSC and collaborators worldwide. See the [Credits](#) page for a detailed list of the organizations and individuals who contributed to the success of this release.

Statistical information

- [Non-Standard Join Certificates](#)
- [Summary Statistics](#)

Fig. 8. Página principal del sitio web Genome Browser, donde se extrajo todo lo referente a los cromosomas.

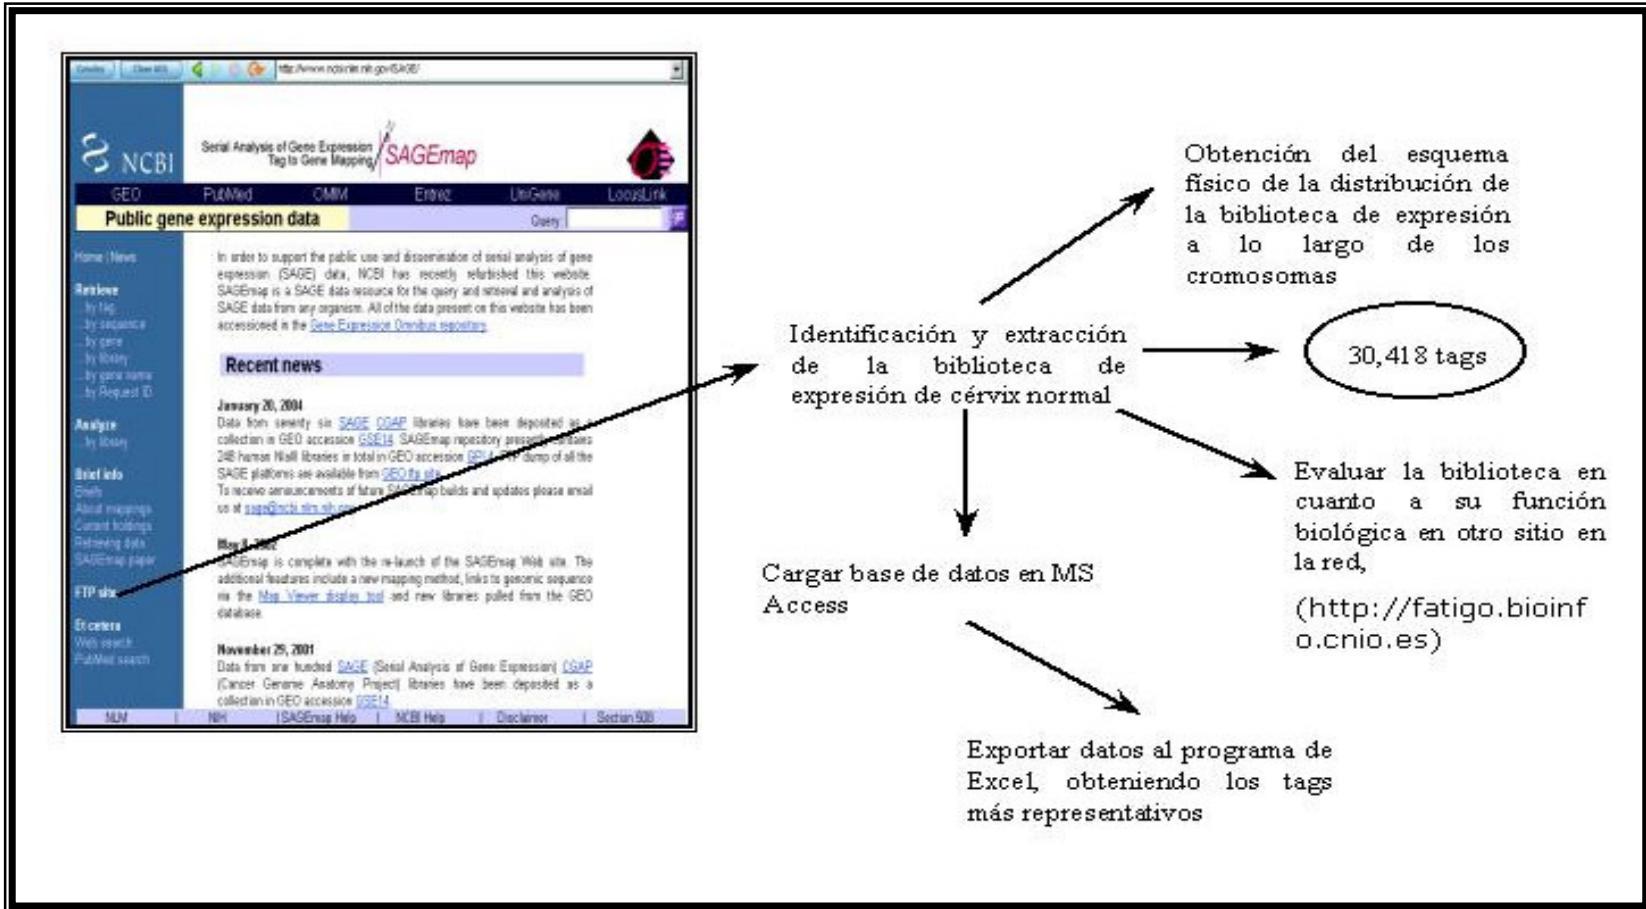
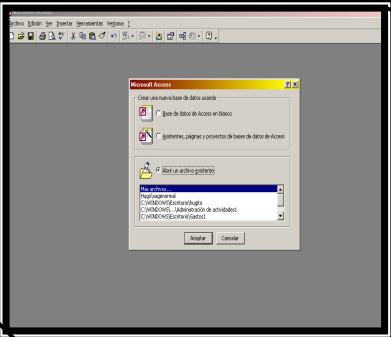


Fig.9. Representación esquemática del proceso de substracción *in silico*. El esquema general muestra como se aplicó la substracción de la Biblioteca de Expresión de Cérvix Normal, y de su tratamiento *in silico* en términos generales.

RESULTADOS Y DISCUSIÓN

Una vez que se realizó el análisis de la biblioteca de expresión de Cérvix en el programa de MC Access, la tabla de resultados se exportó al programa de Excel, en donde se muestra la cantidad de genes totales de la biblioteca, así como el tag de cada gen, el número total de cada tag, y la normalización del número total de cada tag observado sentido la biblioteca, a tags por millón, para facilitar la comparación entre bibliotecas, su número de identificación de Unigene, y el nombre del gen (tabla 1). Del total de la biblioteca (30,418 tags), alrededor de 6,89 songenes (85.1%); 1,207 corresponden a EST's (14.9%).



The screenshot shows the Microsoft Access application window. In the center, there is a message box titled 'Microsoft Access' with the following text:

- Crear una nueva base de datos vacía
- Base de datos de Access en blanco
- Sistemas, páginas y presentaciones de bases de datos de Access
- Abrir un archivo existente

Below the message box, the status bar displays the path: C:\INICIO\Documentos\BIBLIOTECA DE EXPRESION.mdb.

TAG	COUNT	TPM	UNIGNE CLL	GENE NAME
TAOCTGCAGA	515	16930.7647	Hs.100000	S100 calcium binding protein A8 (calgranulin A)
TAGGTTGTCT	356	11703.5966	Hs.279860	tumor protein, translationally-controlled 1
TAGGTTGTCT	356	11703.5966	Hs.374596	ESTs, Highly similar to S06590 IgE-dependent histamine-releasing factor
TTTOCTGCTC	276	9073.57486	Hs.13273	KIAA0592 protein
TTTOCTGCTC	276	9073.57486	Hs.139322	small proline-rich protein 3
GAGGGAGTTT	201	6607.92952	Hs.76064	ribosomal protein L27a
GAGGGAGTTT	201	6607.92952	Hs.356342	ESTs, Highly similar to 2113200C ribosomal protein L27a [Homo sapiens] [H.sapiens]
GTGACCAACGG	188	6180.55099	Hs.299882	ESTs, Highly similar to N-methyl-D-aspartate receptor 2C subunit precursor [Homo sapiens] [H.sapiens]
GTGGOCACGG	184	6049.0499	Hs.112405	S100 calcium binding protein A9 (calgranulin B)
GGGCTGGGGT	173	5687.42192	Hs.90436	sperm associated antigen 7
GGGCTGGGGT	173	5687.42192	Hs.350068	ribosomal protein L29
GCATAATAGG	168	5523.04557	Hs.356482	ESTs, Weakly similar to putative 60S ribosomal protein L21 [Arabidopsis thaliana] [A.thaliana]
GCATAATAGG	168	5523.04557	Hs.350077	ribosomal protein L21
TOAGATCTTT	161	5292.91867	Hs.108124	ribosomal protein S4, X-linked

TABLA 1. Tabla de los 15 genes más representativos de la biblioteca de expresión, así como de los nombres de los genes.

Los genes más representativos dentro del mismo biblioteca podemos agruparlos en base a su abundancia en dos de las tres familias implicadas en el proceso de diferenciación de los queratinocitos; proteínas precursoras de la capa cornificada (SPRRs), proteínas asociadas a filamentos intermedios, y las proteínas asociadas a uniones a calcio (S100s); las cuales se encuentran dentro de una región de 2 Mb en la banda del cromosoma 1q21, llamado el complejo de diferenciación epidermal (CDE). Los patrones de expresión de estos genes durante el desarrollo de los queratinocitos se representan en la Fig. 10.

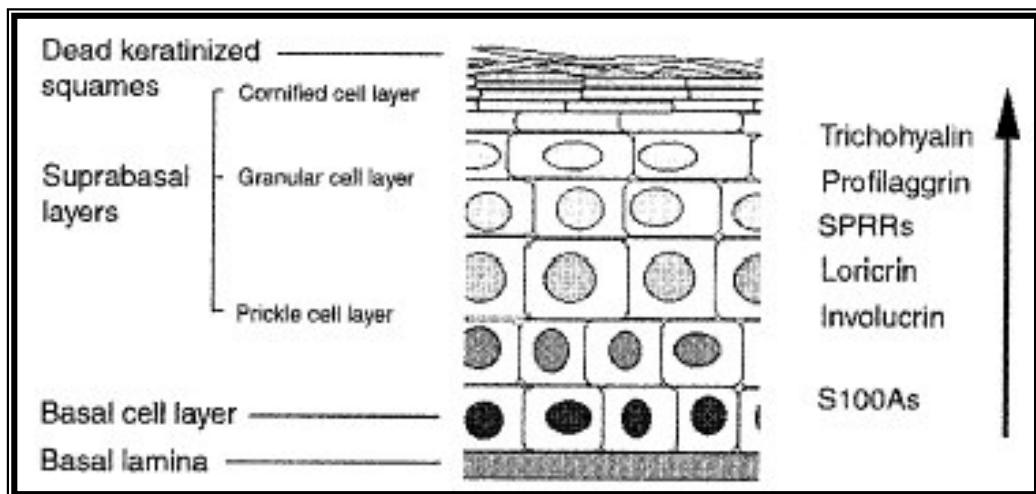


Fig. 10. Diagrama mostrando el proceso de diferenciación de queratinocitos. La flecha muestra la dirección del movimiento celular, desde la capa basal hasta las capas superiores²⁷.

Laco -localizaciónfuncional y estructuralmente de estos genes, aunado a su coordinada expresión durante la diferenciación epidermal nos ha permitido sugerir que están sujetos a algún tipo de mecanismo coordinado de control transcripcional. Asimismo, suele vada la expresión en la biblioteca de Cervix nos permite sugerir que pueden tener un papel importante en la diferenciación del mismo, ya que la región 1q21 está frecuentemente involucrada en reorganización cromosomal en los cánceres humanos ²⁸.

Encuentro su función biológica en la Fig. 11, semuestra la biblioteca de expresión de Cervix, en donde más del 60% de los genes se encuentran referidos al metabolismo. En este contexto la biblioteca se corroboró comparándola con otras bibliotecas de tejidos epitelial es normales, así como en otro sitio web (<http://source.stanford.edu/cgi-bin/sourceSearch>).

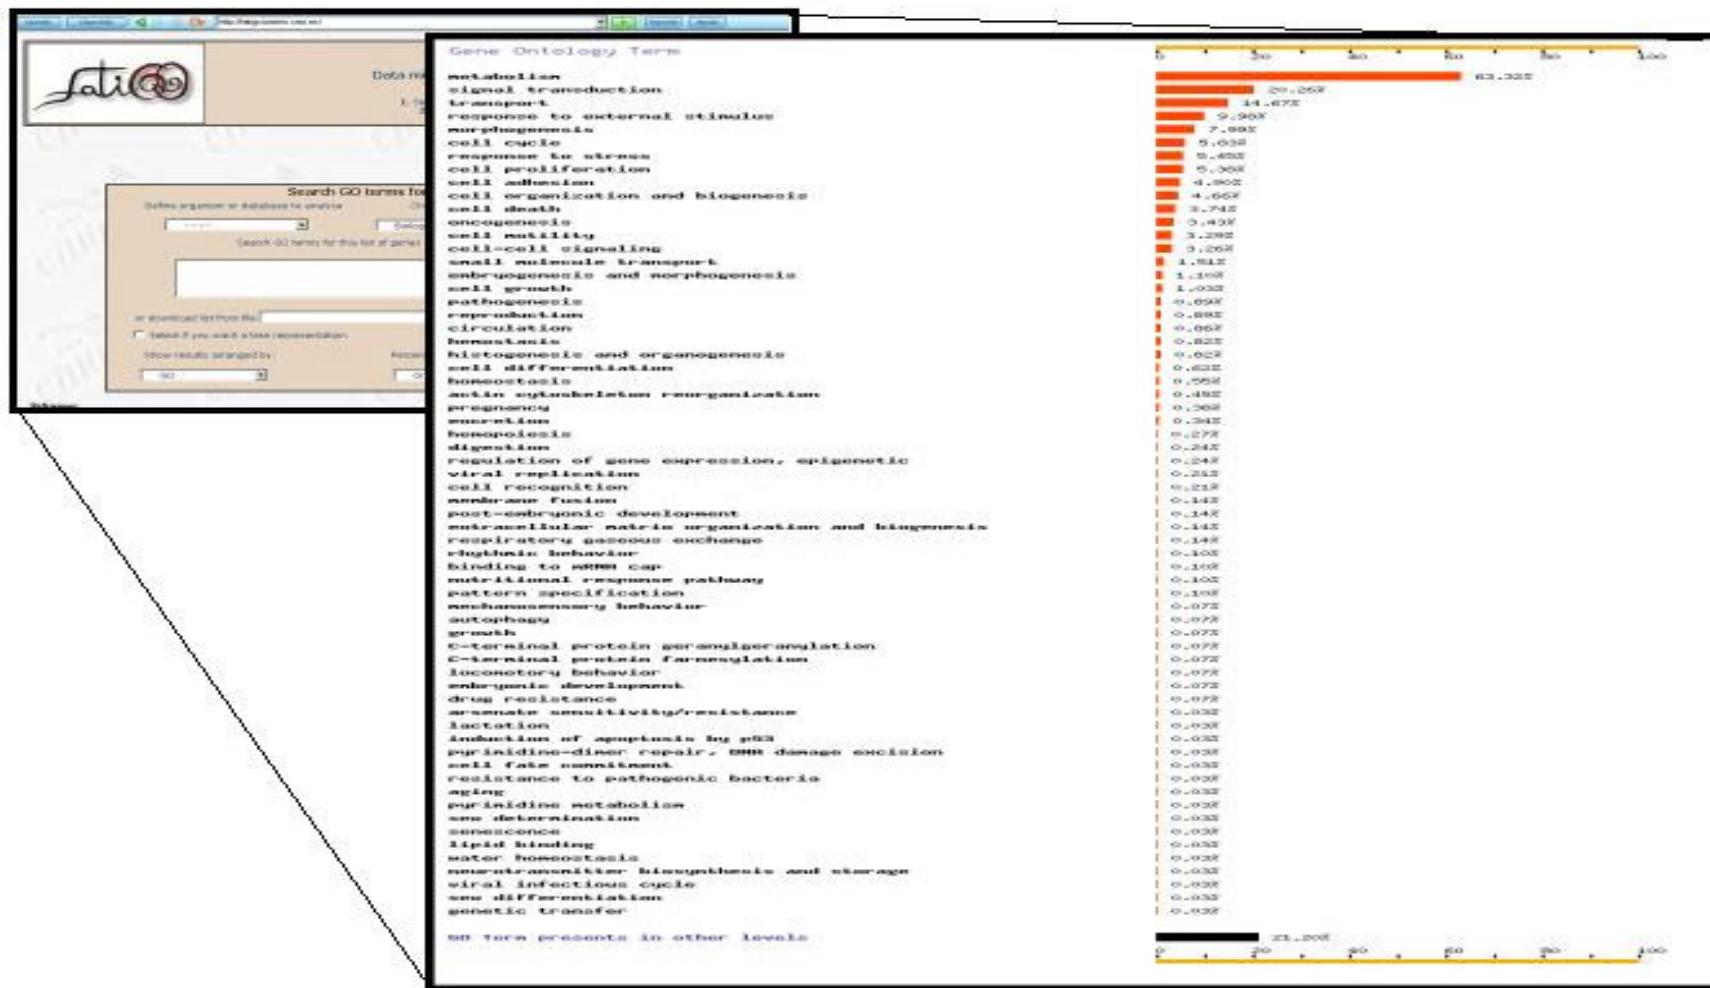


Fig. 11. Representación esquemática de la función biológica de los genes de la Biblioteca de Expresión de Cérvix Normal.

Por otra parte, los datos se sometieron al programa Delta Graphic donde se obtuvo la distribución física de la biblioteca de expresión a lo largo de los cromosomas (Fig. 12). Se puede observar un pequeño agrupamiento muy particular, como es el caso del 1q21, del cual se ha hablado de su gran importancia y relación con cánceres, por su rearrreglo cromosómico. Aunque estudios genéticos en muestras de cáncer cervical han identificado diversos cambios estructurales específicos involucrando los cromosomas 1, 3, 5, 17, y X. A pesar de que los análisis de cariotipo convencionales no han definido alteraciones genéticas involucradas en el carcinoma cervical. Otros estudios con otras técnicas han definido pérdidas de material genético involucrando los cromosomas 2q, 3p, 4p, 4q, 5q, 6q, 11q, 13q, y 18q, y ganancias del 1q, 3q, 5p y 8q en el carcinoma cervical²⁹. Recientes estudios por nuestro grupo aplicando Hibridación Genómica Comparativa con líneas celulares derivadas de cáncer cervical muestran ganancias en las regiones cromosómicas 1q23, 3q11, 3q22, 5p y pérdidas en el 2q, 4p, 6q, 9q, 19³⁰. Estos datos tienen relación, ya que en la Fig. 12 de la biblioteca de expresión de Cervix Normal se muestran agrupamientos muy particulares en los cromosomas 1q, 3q, 5p, 6q, 9q, 12, 17, 19, que puedan estar involucrados en esta neoplasia. Sin embargo, para ayudarnos a explicar cómo es que el genoma humano se comporta en este tejido y así encontrar diferencias en cualquier patología, esta biblioteca de expresión debe ser contrastada con su contraparte tumoral. Esta comparación, es el comienzo para discriminar los cambios en la expresión de los genes que están asociados con la infección integrada del VPH en los queratinocitos cervicales, entre otros. El factor más importante en el desarrollo de esta neoplasia. Actualmente es muy poca la información en términos de expresión diferencial de esta neoplasia.

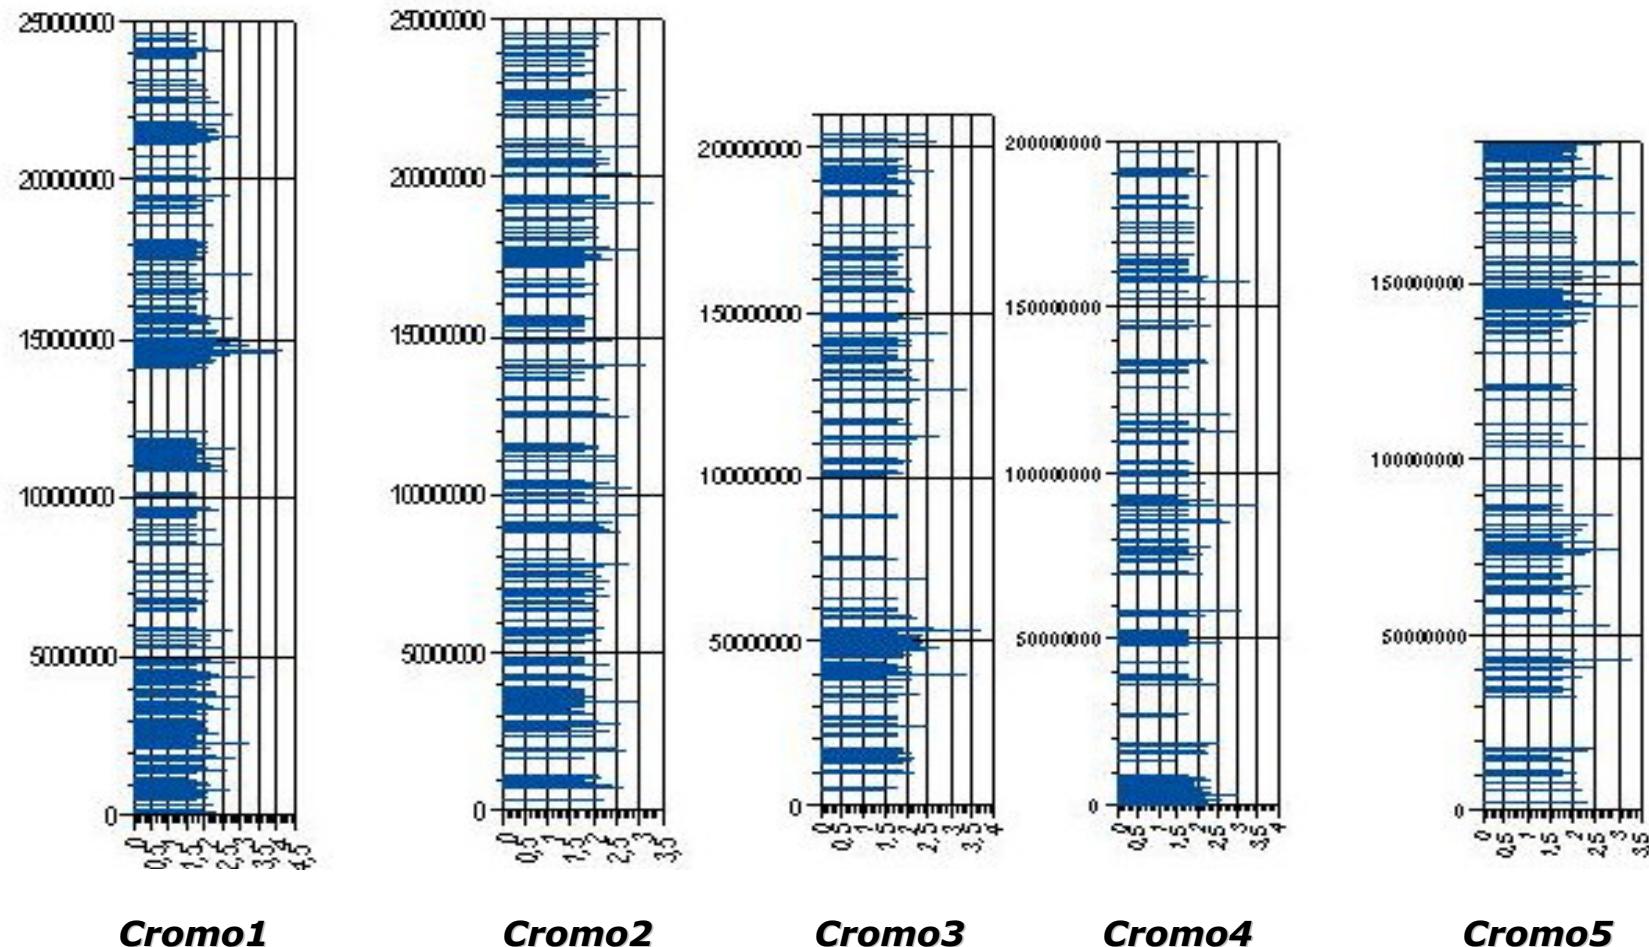
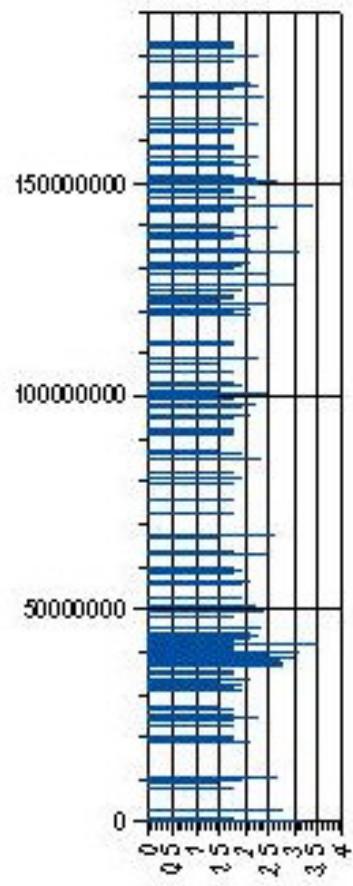
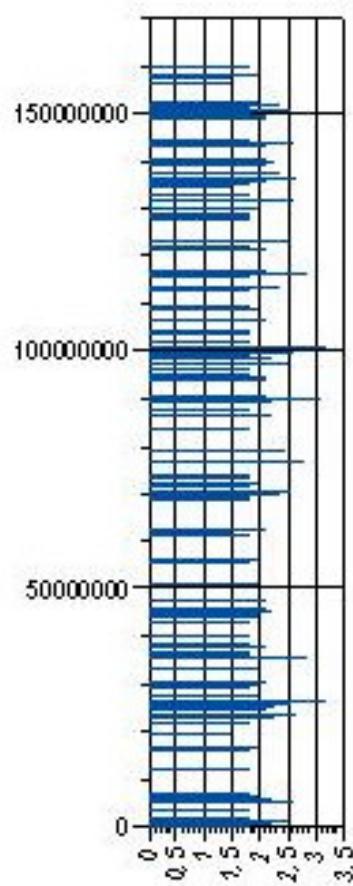


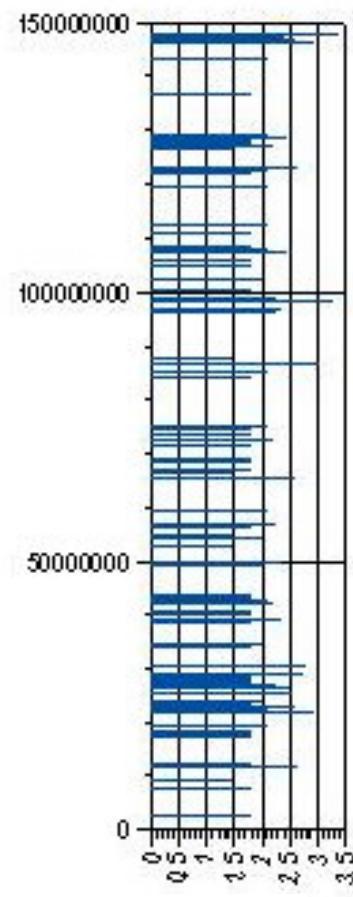
Fig. 12. Caracterización parcial de la Biblioteca de Expresión de Cérvix Normal. Este esquema muestra la distribución de todos los genes de la Biblioteca de Expresión a lo largo de los Cromosomas.



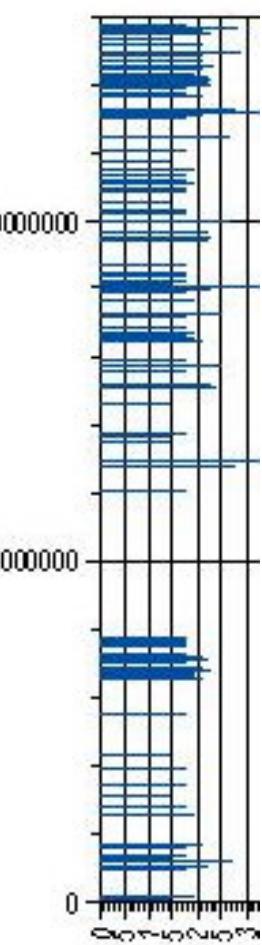
Cromo6



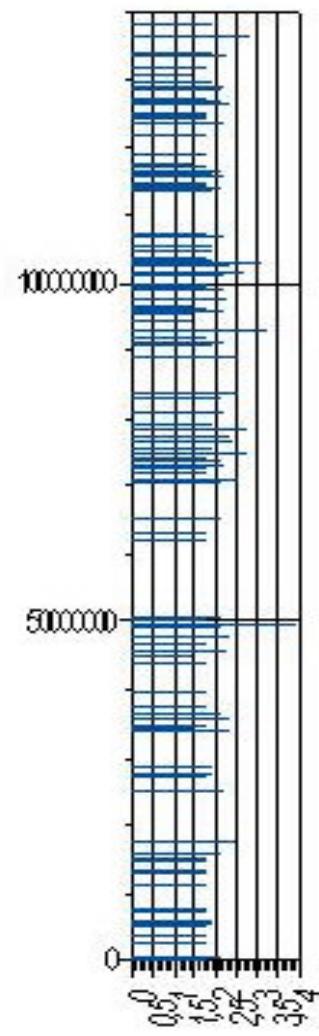
Cromo7



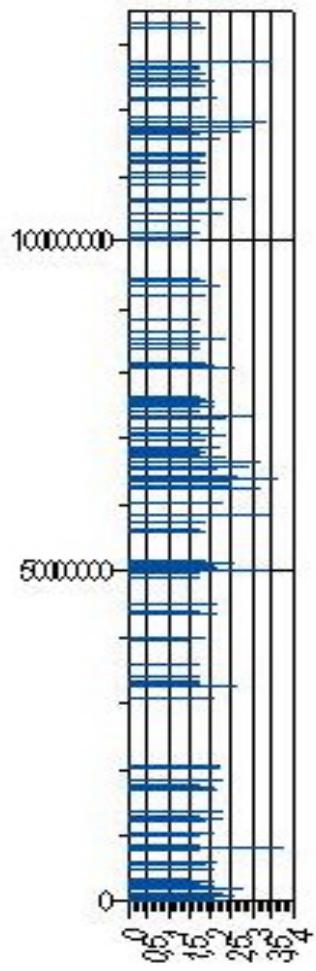
Cromo8



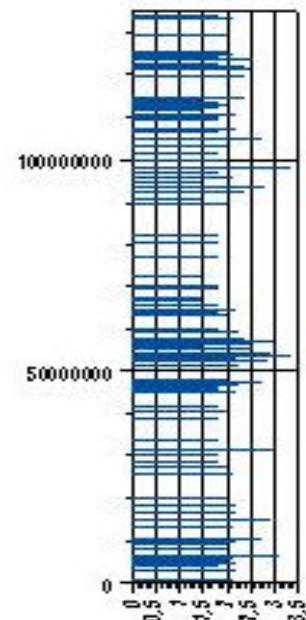
Cromo9



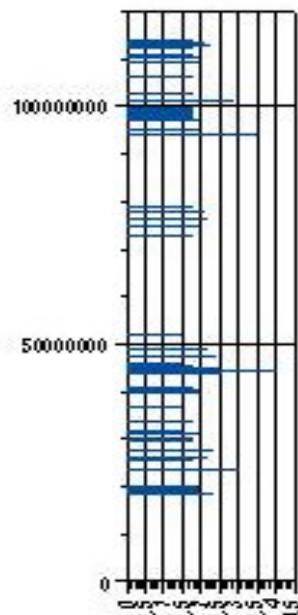
Cromo10



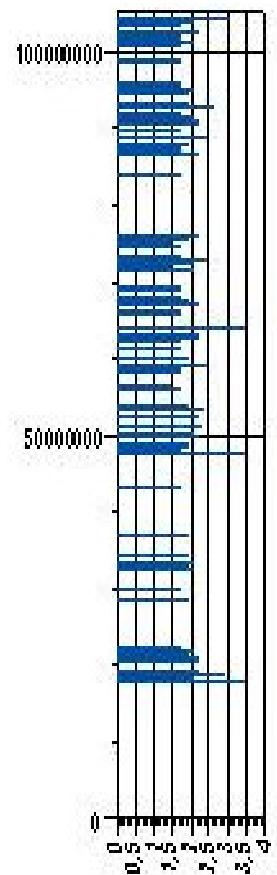
Cromo11



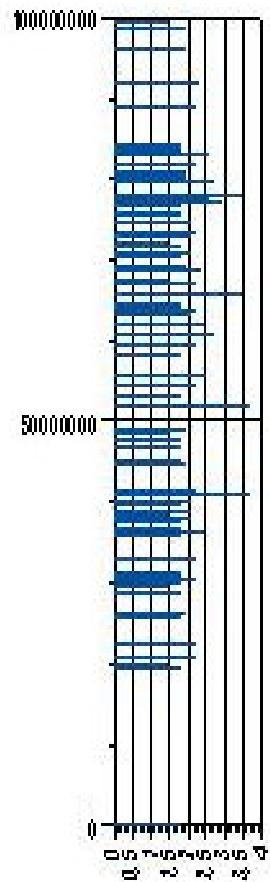
Cromo12



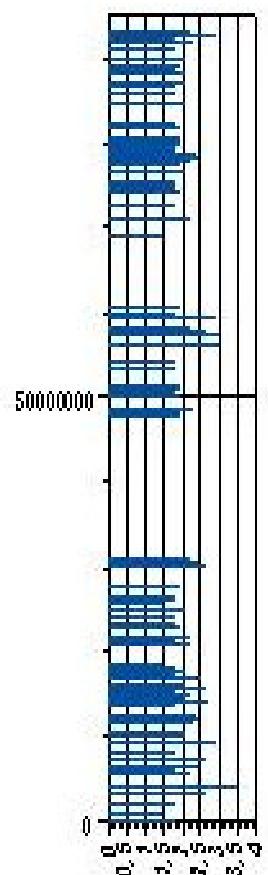
Cromo13



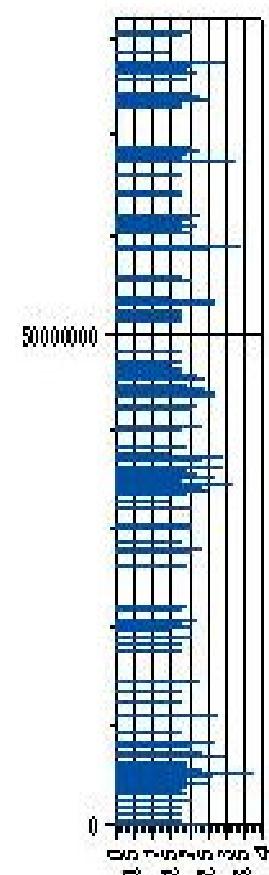
Cromo14



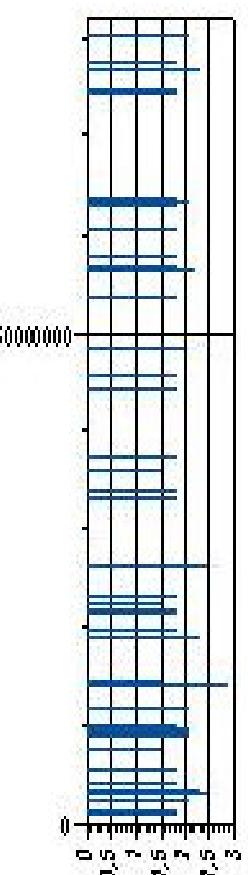
Cromo15



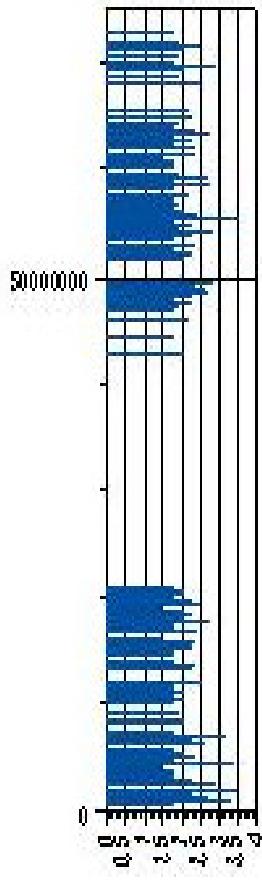
Cromo16



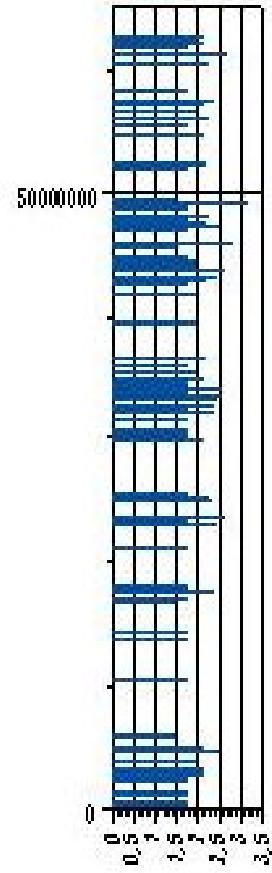
Cromo17



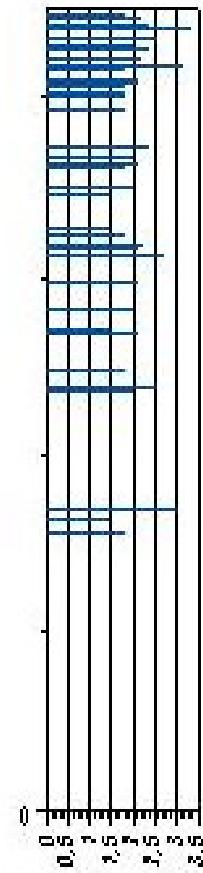
Cromo18



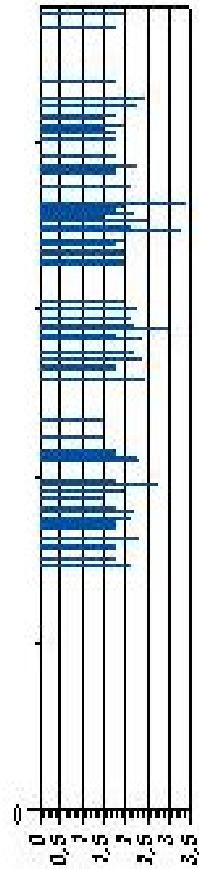
Cromo19



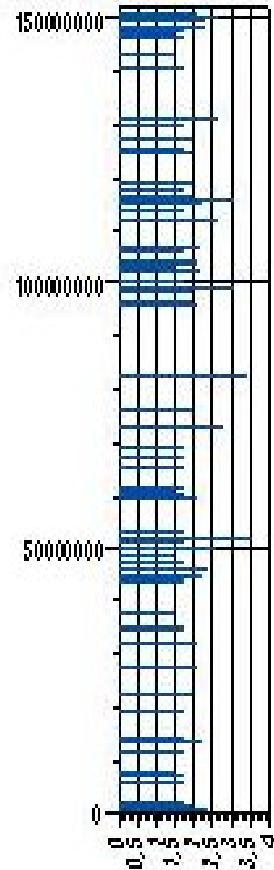
Cromo20



Cromo21



Cromo22



Cromo23

LITERATURA CITADA

1. Rosai J. (1989). Ackerman's Surgical Pathology. Vol. 2. Moscoby Company, Washington,D.C.
2. Kessel R.(1998).Basic Medical Histology.Oxford University.
3. Deaths by cause, sex and mortality stratum in WHO regions, estimates for 1999. World Health Statistics. World Health Organization. www -nt.who.int/whosis
4. Rodríguez, S.A., Ladastida, S., Tapia, R., Kuri, P&Macías C.G. (eds). 1999. México -Salud 2000. Registro Histopatológico de neoplasias en México 1993 -1996. Población de rechahabient edel IMSS.Ciencia y Cultura Latinoamericana,México,D.F.
5. Walboomers, J.M., et al. (1999). Human Papillomavirus is a necessary cause of invasive cervical cancer worldwide. *J. Pathology*;189:12 -19
6. W. Tindle R. (2002) Immune evasion in human papillomavirus-associated cervical cancer. *J Nature Reviews*;2:59 -70
7. Griffiths, T.R., et al. (1999). Human Papillomavirus and Urological Tumors: Basic Science and Role in Penile Cancer;84:579 -86
8. Alani, R.M & Münger, K (1998). Human Papillomavirus and Associated Malignancies. *J Clin Oncol*;16:330 -337
9. Tindle, R.W. (2002). Immune evasion in human Papillomavirus associated cervical cancer. *Nature Reviews Cancer*;2:59 -65
10. Carulli J, Artniger M, Swain Root C, Chee L, Tulig C, Guerin J, Osborne M, Stein G, Lian J, Lomedico P (1998). High throughput of differential gene expression. *J Cell Biochem Suppl*; 30/31: 286-296.

11. PastorianK, Hawel L, ByusC(2000). Optimization of cDNA representational different analysis for the identification of differentially expressed mRNAs. *Analytical Biochemistry*; 283:89 - 98
12. Velculescu V and Vogelstein B(2000) Analysing uncharted transcriptomes with SAGE. *Trends in Genetics* ; 16:423-425
13. Argani P, Rosty C, Reiter R, Wilentz R, Murugesan S, Leach S, Ryu B, Skinner H, Goggins M, Jaffee E, Yeo C, Cameron J, Kern S, Hruban R(2001). Discovery of new markers of cancer through serial analysis of gene expression: prostate stem cell antigen is overexpressed in pancreatic adenocarcinoma. *Cancer Research*; 61:4320 -4324
14. Yamamoto M, Wahatsuki T , Hada A, Ryo A(2001). Use of serial analysis of gene expression (SAGE) technology. *J Immunol Methods*; 250:45-66
15. Margulies EH, Kardia SL, Innis JW(2000). Identification and prevention of a GC content bias in SAGE libraries. *Nucleic Acids Res*; 15:60-70
16. Polyak K, et al. (2001). Gene discovery using the serial analysis of gene expression technique: implications for cancer research. *Journal of Clinical Oncology* ;19:2948 -2958.
17. Sasaki M, Nakahira K, Kawano Y, Katakura H, Yoshimine T, Shimizu K, Kim S, Ikenaka K(2001). MAGE -E1, a new member of the melanoma -associated antigen gene family and its expression in human glioma. *Cancer Res*; 61:4809-4814
18. Polyak K, et al. (2001). A SAGE (serial analysis of gene expression) view of breast cancer tumor progression. *Cancer Research*, 61:5697 -5702.
19. Polyak K, et al. (2001). HIN -1, a putative cytokine highly expressed in normal but not cancerous mammary epithelial cells. *Proceedings of the National Academy of Sciences*, 98:9796 -9801.
20. Yu, J et al. (1999) Identification and classification of p53 regulated genes. *Proc. Natl. Acad. Sci.* 96(25):14517-14522

21. ZhangL,ZhouW,VelculescuV,KernS,HrubanR,Hamilton S,VogelsteinB,KinzlerK(1997).Genenormalexpressionprofiles innormalandcancercells. *Science*;276:1268 -1272
22. Velculescu V. E . et al . (1999) Analysis of human transcriptomes.*NatureGenetics*; 23:387 -388
23. LeerkesMR,CaballeroOL,MackayA,Torloni H,O'HareMJ, Simpson AJ, de Souza SJ. (2002) In silico comparison of the transcriptomederivedfrompurifiednormalbreastcellsandbreast tumor cell lines reveals candidate upregulated genes in breast tumorcells. *Genomics*.2002Feb;79(2):257 -65.
24. Vasmatzis, G. et al. (1997). Discovery of three genes specificallyexpressedinhumanprostatebyexpressedséquense tagdatabaseanalysis.*Proc.Natl.Acad.Sci.*95:300 -04
25. Itoh,k., etal.(1998).Expressionprofileofactivegenesin granulocytes.*Blood*15:1432 -41
26. Diehn M , Sherlock G, Binkley G, Jin H, Matese JC, Hernandez-BoussardT,.ReesCA,CherryJM,Botstein D,.BrownPO and AlizadehAA(2003) SOURCE:a unified genomic resourceof functional annotations, ontologies, and gene expression data; *NucleicAcidsResearch*,31(1):219 -223
27. Ruth, R. E., et al. (2001) Subchromosomal Positioning of the Epidermal Differentiation Complex (EDC) in Keratinocyte and LymphoblastInterphaseNuclei. *Experimental Cell Research*272: 163-175
28. Agnieszka Pietas, et al. (2002). Molecular Cloning and CharacterizationofthehumanS100A14GeneEncodingaNovel Memberof theS100Family.*Genom* 15:513 -522
29. H.RaoPulivarthi,etal.(2004).Chromosomal amplification, 3q gain and deletion of 2q33 -q37 are the frequent genetic changesincervinalcarcinoma. *BMC Cancer*4:1 -9

30. HidalgoAlfredo, et al. (2003). Chromosomal imbalances in four new cervix carcinoma derived cell lines. *BMC Cancer* 3:1471 - 2407