

## BUSCANDO AGUJAS EN UN PAJAR: VIAJES DE RNAs PEQUEÑOS *IN SILICO* E *IN VITRO*

### Finding for a Needle in a Haystack: Trips of Small RNAs from *in silico* to *in vitro*

CLARA ISABEL BERMÚDEZ SANTANA<sup>1</sup>

<sup>1</sup>Departamento de Biología, Facultad de Ciencias, Universidad Nacional de Colombia, Sede Bogotá, Carrera 45 n.º 26-85 - Edificio Uriel Gutiérrez, Bogotá D.C. - Colombia, cibermudezs@unal.edu.co

Presentado 13 de enero de 2011, aceptado 25 de abril de 2011, correcciones 1 de julio de 2011.

#### RESUMEN

Lo que se conoce tradicionalmente como análisis del transcriptoma comprende la caracterización y cuantificación del conjunto de RNAs transcritos en la célula. En los primeros años, los estudios del transcriptoma se enfocaron principalmente a RNA mensajeros o RNA codificantes. Más recientemente, debido a avances en la tecnología de secuenciamiento de última generación, los estudios del transcriptoma se han extendido a RNAs no codificantes. Estas moléculas presentan gran variedad de funciones en la regulación celular. Una caracterización completa del conjunto de ncRNAs no es alcanzable con las aproximaciones disponibles. Hoy en día la identificación de RNAs no codificantes y de sus RNA pequeños derivados, es un tema de vital importancia en el análisis genético. Uno de los avances recientes en el estudio del transcriptoma por ejemplo, se enfoca en la biología de RNA de interferencia y su aplicación clínica. Durante los últimos años se han desarrollado continuamente la capacidad de cómputo, eficiencia y capacidad de almacenamiento para modelar y procesar grandes volúmenes de información producto de secuenciamiento de última generación. Como consecuencia, esta revisión presenta el análisis del transcriptoma desde una perspectiva histórica unida a la modelación computacional de RNA no codificantes de datos de bibliotecas de RNAs pequeños.

**Palabras clave:** transcriptoma, RNA pequeños, secuenciamiento de última generación.

#### ABSTRACT

What is commonly known about transcriptome studies encompass the characterization and quantification of the complete set of RNA transcripts produced by a cell. In its early days these analysis mainly focused on examination of messenger RNAs or coding RNAs. More recently, due to advances in next-generation sequencing technologies, transcriptome analysis has expanded to non-coding RNAs (ncRNAs). These molecules exhibit high variety of functions in cell regulation. Through characterization of complete sets of ncRNAs is not attainable with current approaches. At present de novo identification of ncRNAs and ncRNA-derived small RNAs is a major issue in genetic analysis. One of the

most important recent advances of transcriptome analysis focuses, for example, on RNA interference (RNAi) biology and its clinical application. High-performance computing, storage capability and computational modeling have been continuously developed during last years to process and model large amounts of products of next generation sequencing methods. As consequence this review describes transcriptome sequencing analysis from a historical perspective to its link to computational approaches to model ncRNAs from small RNA library data.

**Key words:** Transcriptome, small RNAs, next-generation sequencing technology.

## INTRODUCCIÓN

El transcriptoma se define como el conjunto de todas las moléculas funcionales de RNAs producto de la expresión de genes en una célula o, en una población de células y, con más detalle, como la cuantificación de material transcrito y su relación con la expresión diferencial de genes (Morozova *et al.*, 2009). De esta inmensa población molecular, una primera porción se compone de RNA mensajeros, producto de la transcripción de genes que finalmente son traducidos en proteínas y, una segunda porción, no menos importante para la fisiología celular, se compone de RNAs no codificantes, también producto de la transcripción, con funciones diversas como su papel en la formación de ribonucleoproteínas, adaptación de aminoácidos en la traducción y para el caso particular de los más pequeños (tema principal de esta revisión), la regulación de la expresión génica mediada por RNAs.

El análisis del transcriptoma, bien sea por la estimación de su tamaño, o por la identificación de los tipos de RNAs, entre otros, es una tarea compleja, aún en desarrollo y compromete múltiples esfuerzos de la investigación experimental (*in vitro*) y computacional (*in silico*). La parte experimental comprende aislamiento y secuenciamiento de productos de la transcripción, su tipificación y cuantificación. Desde los trabajos iniciales de Sanger (Sanger y Coulson, 1974; Sanger *et al.*, 1977; el único método de secuenciamiento usado por muchos años) la biología se ha visto beneficiada por el secuenciamiento de genomas de muchos organismos, y por el conocimiento ganado sobre el análisis del transcriptoma. Sin embargo, la necesidad de disminuir costos e incrementar el rendimiento del secuenciamiento, conllevó al desarrollo de nuevos métodos conocidos hoy como de última generación. Estos han logrado el resecuenciamiento de genomas, lo esperado en la relación costo-eficiencia, una disminución de costos y un incremento en la eficiencia del secuenciamiento. Debido al descubrimiento de nuevos RNAs y de nuevos detalles de análisis de la maquinaria asociada a su biogénesis y función (Tanzer *et al.*, 2010), y hoy por hoy, hemos expandido nuestras fronteras del conocimiento al estudio de los caminos de regulación de la expresión de genes mediada por RNAs pequeños.

### DESDE SANGER HASTA LOS MÉTODOS DE SECUENCIAMIENTO DE ÚLTIMA GENERACIÓN

En 1977, utilizando el método de Sanger, fue secuenciado en su totalidad el primer genoma, constituido por 5.386 nucleotidos, perteneciente al bacteriófago phiX174 (Sanger *et al.*, 1977). Este método se conoce como de terminación de cadena o méto-

do de secuenciamiento enzimático (Sanger y Coulson, 1974; Sanger *et al.*, 1977). Aunque previamente otros métodos de secuenciamiento fueron utilizados (Gilbert y Maxam, 1973), el método de Sanger se convirtió en el predilecto para secuenciamiento de DNA. Modelos utilizados actualmente como *Applied Biosystems 3xxx series* o *GE Healthcare MegaBACE*, utilizan el mismo concepto de secuenciamiento (Kircher y Kelso, 2010) con un ligero incremento del rendimiento por la automatización de algunos pasos, el uso de electroforesis capilar (Swerdlow y Gesteland, 1990; George *et al.*, 1997) y el uso de una sola reacción en el proceso (Smith, 1986; contrario al método original de Sanger en el cual cuatro reacciones y lecturas separadas se realizaban: una por cada terminador de cadena marcado radioactiva u ópticamente). Sin embargo, el término original “secuenciamiento de alto rendimiento” fue acuñado para el secuenciamiento automatizado del método de Sanger donde la tecnología incluye más capilares, (de 96 y posible hasta 384 capilares) entre otros. Sin embargo, este concepto ha sido completamente reevaluado y quizás en un futuro de nuevo cambiará cuando surjan nuevas tecnologías (Kircher y Kelso, 2010).

Actualmente, el uso métodos de secuenciamiento de últimas generaciones han transformado las ciencias genómicas y muchos campos de la biología (Schuster, 2008). Estas tecnologías, de bajo costo y alto rendimiento se utilizaron por primera vez en 2005 cuando un sistema de secuenciamiento en paralelo, desarrollado por “454 Life Sciences”, fue reportado para ensamblar y secuenciar de novo el genoma de *Mycoplasma genitalium* (Margulies *et al.*, 2005). Simultáneamente, el laboratorio de George Church reportó el protocolo de secuenciamiento “*multiplex polony*” utilizado por primera vez para resecuenciar el genoma de una cepa de *Escherichia coli* (Shendure *et al.*, 2005). Otros estudios en biología han utilizado el sistema de secuenciamiento paralelo masivo como la tecnología desarrollada por Solexa (Bentley *et al.*, 2008), hoy conocida como *Illumina SBS technology*, para identificar modificaciones de histonas en cromatina humana (Barski *et al.*, 2007), o la tecnología “*ChIPSeq*” (Johnson *et al.*, 2007). Uno de los pasos experimentales de las nuevas tecnologías de secuenciamiento corresponde al reemplazo del clonado *in vivo* (como es necesario en el secuenciamiento de Sanger) por amplificación *in vitro* basada en PCR. Las tecnologías desarrolladas (por ejemplo 454, Illumina y SOLiD), producen una colección clonal de copias que son posteriormente secuenciadas. Un método, que elimine el paso de amplificación y basado en secuenciamiento directo de una única molécula implementado por Helicos y *Pacific Biosciences* aún en desarrollo es referido como método de tercera generación (Braslavsky, 2003; Morozova, 2009). Este método se proyecta aun más eficiente por la reducción de costos y disminución de pasos en el secuenciamiento de segunda generación.

Finalmente, la tecnología de secuenciamiento de última generación ha sido utilizada para descifrar la complejidad de la expresión celular. En combinación con métodos para cuantificar transcritos y sus isoformas, la aproximación RNA-seq (Wang *et al.*, 2009) ha permitido el mapeo y cuantificación de transcriptomas de mamíferos (Mortazavi *et al.*, 2008), caracterización de transcriptomas de células madre, de líneas celulares de cáncer de seno, de células HeLa (Marioni *et al.*, 2008; Cloonan *et al.*, 2008; Zhao *et al.*, 2009) y de levadura entre otros. Adicionalmente, esta nueva herramienta ha permitido el surgimiento de una de las principales áreas de la genética moderna: el estudio de promotores alternativos (Strausberg y Levy, 2007).

#### **ANÁLISIS DEL TRANSCRIPTOMA: UNA BREVE PERSPECTIVA HISTÓRICA**

Los primeros estudios del transcriptoma se basaron en aislamiento de RNA total de diferentes tejidos y el uso de la técnica de “*Northern blot*” para la detección de transcritos (Alwine, 1977). Las limitaciones dadas por el requerimiento de volúmenes grandes de RNA para el análisis, fueron posteriormente superadas por el uso de PCR cuantitativa de transcripción reversa o (RT-qPCR; Becker-Andre y Hahlbrock, 1989). Sin embargo, aún después de su amplio uso, esta no permite analizar un transcriptoma a gran escala (Morozova, 2009). Posteriormente, la era de los chips de microarreglos de DNAs (*microarrays*; Schena, 1995), ha logrado analizar la expresión diferencial de genes en líneas celulares y estudiar patrones del transcriptoma a gran escala. Aunque es una técnica robusta, la medición de la expresión es indirecta y no corresponde a una medida explícita de expresión génica. Algunas alternativas complementarias a los chips de DNAs son los métodos basados en secuenciamiento que permiten directamente la detección de transcritos y más recientemente, la estimación de la abundancia de la expresión (Morozova, 2009). Estos métodos varían desde la construcción y secuenciamiento de librerías de DNA complementario o cDNA, el uso de secuenciamiento de EST (*Expressed Sequence Tags* por su sigla en inglés) hasta los métodos SAGE (*Serial Analysis of Gene Expression*), ofreciendo ventajas sobre las técnicas de chips de DNA por que su uso facilita el secuenciamiento tipo Sanger para estudiar expresión génica (Velculescu *et al.*, 1995). Finalmente, como se mencionó en la sección anterior, los últimos estudios de transcriptoma a gran escala actualmente se basan en la tecnología de secuenciamiento de última generación como técnica de secuenciamiento directo del transcriptoma.

#### **SOBRE LAS DESVENTAJAS DEL SECUENCIAMIENTO Y LOS GRANDES BENEFICIADOS: LOS RNAs PEQUEÑOS**

Los métodos de secuenciamiento de última generación producen lecturas, secuencias producto de la secuenciación conocidas como *reads*, que varían desde 20 hasta 500 nucleótidos. Sin embargo, el volumen de lecturas de tamaño pequeño producto del secuenciamiento puede superar el orden de  $10^6$  por ronda de secuenciación (Kircher y Kelso, 2010) y este manejo de datos fue considerado una desventaja y fuente de crítica en los primeros años de su utilización; primero, por la dificultad de almacenamiento, y segundo por la gran demanda de recursos que dificultó el trabajo computacional para realizar el ensamble, por ejemplo, de un genoma en corto tiempo. Como resultado también se incrementaron los requerimientos de nuevos algoritmos para el análisis.

No obstante, la disponibilidad de lecturas de tamaño pequeño desarrolló una nueva área de investigación para la identificación de RNAs pequeños. El temor de manejar, depurar y anotar (asignar un *locus* correspondiente) a millones de productos, fue rápidamente reemplazado por el uso eficiente de recursos computacionales. Cientos de laboratorios de biología computacional y bioinformática se han consolidado a nivel mundial con el fin de desarrollar un *software* comercial o de uso libre con fines académicos. Los laboratorios altamente tecnificados poseen repositorios para bases de datos de productos de secuenciamiento, secuencias de genomas, códigos de programación en desarrollo, interfaces de internet para análisis de “ómicas”, y una comunidad científica que trabaja interdisciplinariamente para estructurar redes de intercambio de información, elaborar y depurar algoritmos para interpretar cuál es el destino final de los productos de secuenciamiento,

ensamblar genomas en unos casos y, en otros, como en el análisis de transcriptoma para establecer valores de referencia de expresión y hacer la respectiva anotación genómica. Para los RNAs pequeños queda un mundo por descubrir, un reto continuo para los investigadores en ciencias de la computación: desarrollo de herramientas computacionales para la identificación de genes blanco, de su regulación, identificación de las regiones genómicas que los codifican, predicción automatizada *de novo*, normalización de datos de su expresión, investigación de su potencial en nuevas terapias y diagnóstico de enfermedades. En palabras de Schuster, 2008, “biólogos y científicos de la computación continúan enfrentándose a nuevos retos para transformar la biología de hoy. Este objetivo será alcanzado a través del desarrollo de modelos computacionales estructuralmente enlazados con la bioquímica, la biofísica y el manejo de los datos experimentales. Una vez desarrollados estos modelos, por medio de ingeniería moderna y computacional se podrán simular, analizar y comprender los datos para de nuevo avanzar en el diseño de nuevos experimentos”.

#### **EL TRANSCRIPTOMA Y LAS CIENCIAS DE LA COMPUTACIÓN: ANOTACIÓN E IDENTIFICACIÓN DE RNAs PEQUEÑOS**

Aunque fue superado el problema del manejo de volumen de productos del secuenciamiento, una nueva dificultad surgió debido a errores incorporados en las lecturas. Dependiendo de la técnica usada para secuenciar, errores son incorporados en las lecturas -inserciones, deleciones o sustituciones. Por ejemplo en Solexa, el tipo más común de error es sustitución, y en la tecnología 454 inserción o deleción (Hoffmann *et al.*, 2009). Entonces, la demanda para el desarrollo de nuevos métodos computacionales de mapeo (es decir el asignamiento de las regiones genómicas de las cuales son derivadas las lecturas; ver Fig. 1 como ejemplo), se ha incrementado en los últimos años y debe responder de forma robusta al manejo de errores incorporados en las lecturas. Es decir, las nuevas herramientas computacionales dirigidas a resolver este problema han sido desarrolladas para permitir apareamientos no correspondientes entre la secuencia de la lectura y la secuencia de la región genómica blanco. La mayor parte de las herramientas actuales son modificaciones o adaptaciones de técnicas de alineamiento, que deben permitir de forma óptima la incorporación de pequeños huecos y errores mínimos de no apareamiento entre secuencias, para lograr finalmente un mapeo óptimo de lecturas y secuencia genómica de referencia (en otras palabras, cuando una lectura es mapeada al genoma lo esperado es encontrar correspondencias únicas entre nucleótidos, A con A, G con G, etc). Algunos de los programas actuales como SOAP (Li *et al.*, 2008) y Maq (Li *et al.*, 2008) mapean resultados de SOLEXA o SOLiD. SOAP realiza alineamientos con o sin huecos, pero no permite la manipulación de inserciones, deleciones y sustituciones. Actualmente, el programa segemehl (Hoffmann *et al.*, 2009) permite mapeo evaluando estadísticamente todas las fuentes de error posibles del producto del secuenciamiento.

Un resultado a primera vista del mapeo es la observación de lecturas acumuladas en ciertas regiones del genoma. Estos bloques de expresión (ver como ejemplo Fig. 2) son anotados computacionalmente y a su vez son candidatos potenciales para identificar la expresión de RNA pequeños aún desconocidos. Por otro lado, el procesamiento de RNAs y el estudio de producción de nuevas fuentes de RNAs pequeños, es posible

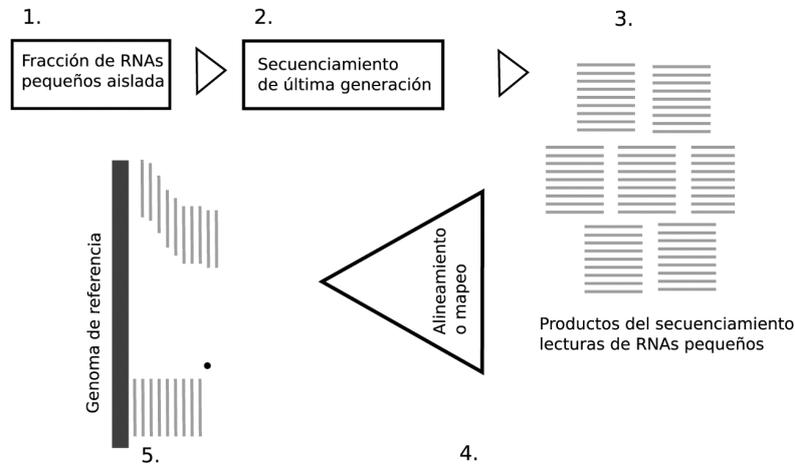


Figura 1. Pasos para el mapeo de lecturas producto del secuenciamiento de última generación a un genoma de referencia. De una fracción aislada de RNAs pequeños (paso 1) se genera una librería para ser secuenciada utilizando una de las tecnologías disponibles (paso 2). Los productos del secuenciamiento pueden ser filtrados (paso 3) y posteriormente alineados o mapeados a un genoma de referencia (paso 4). Finalmente comparando con anotaciones existentes se puede anotar el RNA pequeño o ser considerado como uno nuevo (paso 5).

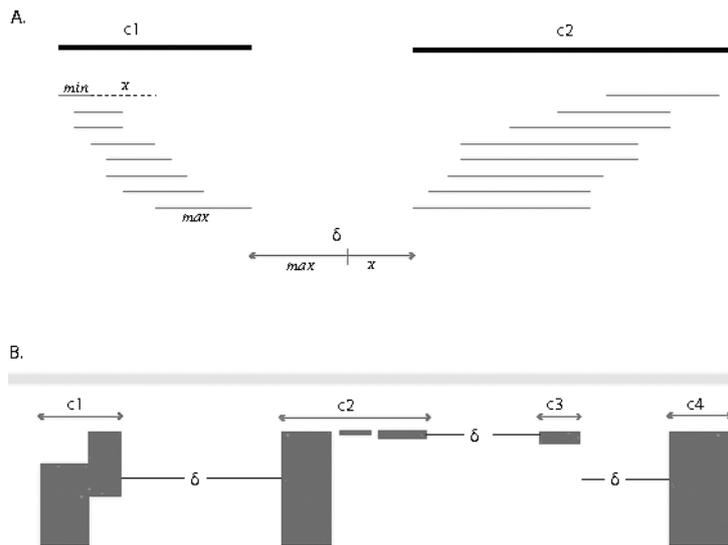


Figura 2. Esquema de identificación de bloques de expresión en datos de transcriptoma. En A,  $c1$  y  $c2$  corresponden a regiones *clusters* o aglomeraciones de lecturas mapeadas. Una vez las lecturas han sido mapeadas, acumulaciones de ellas son observadas sobre regiones del genoma de referencia. Los conjuntos denominados  $c1$ ,  $c2$ ,  $c3$  en B, corresponden a posibles bloques de expresión de la región. Sin embargo, identificar el gen del cual son transcritos implica asociar distancias umbral para anotar el locus correspondiente. En este caso  $\delta$  (delta),  $max$  y  $min$  (máximo y mínimo del tamaño de lectura; Bermudez-Santana, 2010).

gracias al trabajo en conjunto de experimentalistas y científicos de las ciencias de la computación (ver como ejemplo Fig. 3).

Entonces, el uso de herramientas computacionales permiten hoy en día analizar de forma eficiente el transcriptoma y anotar de manera automática nuevas regiones del genoma que producen RNAs pequeños, así como la visualización de patrones de procesamiento de los RNAs. Aun está abierta la pregunta sobre conocer si estos patrones de expresión pueden corresponder a productos de caminos de control de calidad de los RNAs o a procesamiento de RNAs que posteriormente pueden producir RNAs pequeños funcionales (Langenberger *et al.*, 2010). En la figura 3 se observan algunos ejemplos de patrones de expresión asociados a RNAs.

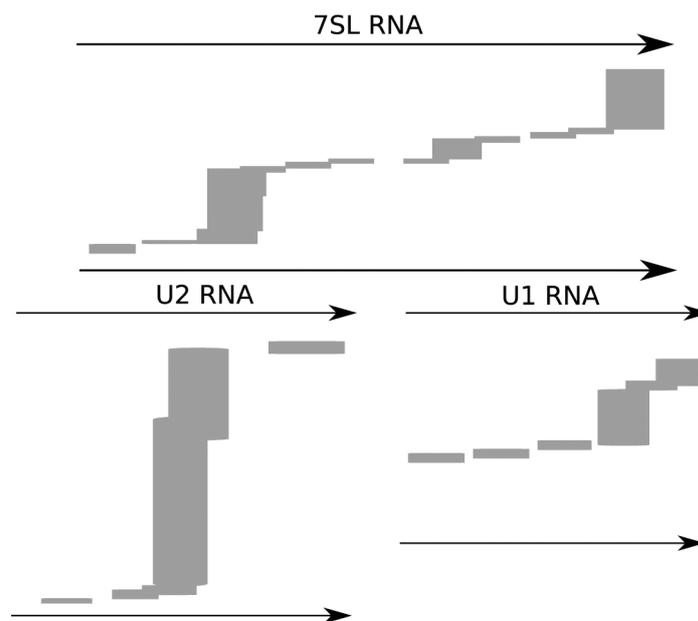


Figura 3. Patrones de procesamiento de RNAs pequeños identificados por medio de secuenciamiento de última generación. Las lecturas son mapeadas y visualizadas por medio de herramientas computacionales. Este ejemplo corresponde a una librería de RNAs pequeños de tejido de cerebro humano mapeados al genoma de referencia humano (Langenberger *et al.*, 2009; Langenberger *et al.*, 2010). Se observan diferentes patrones de procesamiento en general. Vea como ejemplos, patrones para el 7SL RNA y RNAs nucleares pequeños U1, U2. Adaptación del autor desde (Langenberger *et al.*, 2010; Bermudez-Santana, 2010), las flechas indican el sentido de loci en el genoma y su tamaño.

#### **RNAs PEQUEÑOS, CAMINOS DE REGULACIÓN Y SECUENCIAMIENTO DE ÚLTIMA GENERACIÓN**

Uno de los principales impactos del uso de nuevas tecnologías de secuenciamiento responde a la caracterización de la regulación de la expresión génica mediada por RNAs pequeños proceso conocido como RNA de interferencia (RNAi). Este proceso biológico es principalmente basado en la función de tres clases de RNA pequeños, microRNAs (miRNAs), RNA pequeños de interferencia (siRNA) y piwiRNAs (piRNAs). El camino fue descubierto entre 1986 y 1990 a través de observaciones de inhibición transcripcional

por RNAs antisentido expresados en plantas transgénicas (Ecker y Davis, 1986) y resultados experimentales en inicios de 1990 (Napoli *et al.*, 1990). Aunque el descubrimiento del camino RNAi precede las nuevas tecnologías de secuenciamiento, hoy en día los estudios más detallados de caminos de silenciamiento de genes mediados por el RNAi, son exclusivamente posibles por la existencia de esta tecnología (Haussecker *et al.*, 2010). El RNAi describe una variedad de procesos de silenciamiento de genes mediados por RNAs pequeños que guían complejos macromoleculares para completar su función. Estos caminos de silenciamiento asociados a diferentes proteínas se clasifican en tres mecanismos principales para la regulación de genes: el primero es la inhibición traducional, donde miRNAs se enlazan a RNA mensajeros e inhiben la traducción, el segundo comprende RNAs pequeños que marcan RNAs mensajeros blanco y causan degradación por medio de la activación del sistema de silenciamiento inducido por RNA. Algunos RNAs pequeños que hacen parte de este camino son los miRNAs, siRNA, piRNAs entre otros. El tercer camino corresponde al silenciamiento de genes por medio de metilación guiada por RNAs pequeños. Una revisión más detallada de los caminos puede consultarse en Mette *et al.*, 2002, Bhattacharyya *et al.*, 2008 y Tanzer *et al.*, 2010.

#### **DATOS SOBRE RNAs PARA CONSULTAR**

Finalmente, existen muchos motivos para continuar profundizando sobre la biología de RNAs pequeños y su unión con el mundo RNA. Familias de RNAs están disponibles en <http://rfam.sanger.ac.uk/> (Gardner, 2009). Utilizando herramientas computacionales y secuencias de RNAs validadas experimentalmente, actualmente son reportadas 1446 familias de RNAs. El consorcio internacional de RNA *RNA Ontology Consortium* (ROC) <http://roc.bgsu.edu/>, se encuentra disponible para definir un marco conceptual sobre la investigación de RNA, programas de cómputo disponibles y de uso en diferentes plataformas como Linux, Windows están disponibles bajo licencia o de uso libre por laboratorios computacionales.

#### **CONCLUSIONES**

Los estudios en genómica y transcriptómica se han desarrollado principalmente por nuevos métodos de secuenciamiento y desarrollo computacional. Desde los trabajos pioneros de aplicación de técnicas de secuenciamiento y otros métodos, nuestro conocimiento sobre la expresión diferencial de genes y la organización genómica de diversos organismos se ha incrementado. Históricamente, el incremento en la eficiencia del secuenciamiento requerido por los investigadores conllevó paralelamente al encuentro entre disciplinas de las ciencias de la computación y la biología debido a la necesidad de procesar, almacenar de forma eficiente, sistematizada y computacional millones de productos de secuenciamiento y a las necesidades de construir bases de datos, desarrollar e implementar nuevos algoritmos para alinear los productos de secuenciamiento a los genomas de referencia.

Nuevas preguntas de investigación relacionadas con el análisis del transcriptoma han surgido y paralelamente han nutrido el desarrollo de diferentes métodos computacionales. Muchos de los algoritmos disponibles y próximos a implementar, han incrementado nuestro conocimiento de los componentes del transcriptoma y a su vez han

---

ampliado nuestro conocimiento sobre los componentes de menor tamaño o RNAs pequeños. Estos pequeños RNAs nos han sorprendido y nos seguirán sorprendiendo una vez su importancia en la regulación de la expresión genética mediada por RNAs sea conocida en más detalle y nuevas funciones sean descubiertas.

### AGRADECIMIENTOS

La autora agradece a Peter F. Satdler, David Langenberger y Steve Hoffmann de la Universidad de Leipzig y a Martin Kircher de MPI-EVA de Leipzig por sus discusiones y bibliografía que aportaron al marco conceptual de esta revisión. A los organizadores de la Cátedra José Celestino Mutis “Todo lo que Usted quiso saber de genética y nunca se atrevió a preguntar.”

### BIBLIOGRAFÍA

ALWINE JC, KEMP DJ, STARK GR. Method for Detection of Specific RNAs in Agarose Gels by Transfer to Diazobenzoyloxymethyl-paper and Hybridization with DNA Probes. *Proc Natl Acad Sci U S A.* 1997;74:5350-5354.

BARSKI A, CUDDAPAH S, CUI K, ROH TY, SCHONES DE, WANG Z, *et al.* High-resolution Profiling of Histone Methylations in the Human Genome. *Cell.* 2007;129(4):823-837.

BERMUDEZ-SANTANA C. tRNomics: Genomic Organization and Processing Patterns of tRNAs. Tesis de Doctorado. Leipzig (Alemania). Facultad de Matemáticas e Informática, Universidad de Leipzig; 2010

BHATTACHARYA SN, FILIPOWICZ W, SONENBERG, N. Mechanisms of Posttranscriptional Regulation by MicroRNAs: Are the Answers in Sight? *Nat Rev Genet.* 2008;9(NIL):102-104.

BRASLAVSKY I, HEBERT B, KARTALOV E, QUAKE SR. Sequence Information can be Obtained from Single DNA Molecules. *Proc Natl Acad Sci U S A.* 2003;100:3960-3964.

BECKER-ANDRE M, HAHLBROCK K. Absolute mRNA Quantification Using the Polymerase Chain Reaction (PCR). A Novel Approach by a PCR Aided Transcript Titration Assay (PATTY). *Nucleic Acids Res.* 1989;17:9437-9446.

BENTLEY DR, BALASUBRAMANIAN S, SWERDLOW HP, SMITH GP, MILTON J, BROWN CG, *et al.* Accurate Whole Human Genome Sequencing Using Reversible Terminator Chemistry. *Nature.* 2008;456:53-59.

CLOONAN N, FORREST A, KOLLE G, GARDINER B, FAULKNER G, BROWN M, *et al.* Stem Cell Transcriptome Profiling Via Massive-scale mRNA Sequencing. *Nat Methods.* 2008;5(7):613-619.

ECKER JR, DAVIS RW. Inhibition of Gene Expression in Plant Cells by Expression of Antisense RNA”. *Proc Natl Acad Sci U S A.* 1986;83(15):5372-5376. doi:10.1073/pnas.83.15.5372.

GARDNER PP, DAUB J, TATE JG, NAWROCKI EP, KOLBE DL, LINDGREEN S, *et al.* Rfam: Updates to the RNA Families Database. *Nucleic. Acids Res.* 2009; 37:D136-D140.

GEORGE KS, ZHAO X, GALLAHAN D, *et al.* Capillary Electrophoresis Methodology for Identification of Cancer Related Gene Expression Patterns of Fluorescent Differential Display Polymerase Chain Reaction. *J Chromatogr B Biomed Sci Appl.* 1997;695:93-10.

GILBERT W, MAXAM A. The Nucleotide Sequence of the Lac Operator. *Proc Natl Acad Sci U S A.* 1973;70:3581-3584.

HAUSSECKER D, HUANG Y, LAU A, PARAMESWARAN P, FIRE A, KAY M. Human tRNA-derived Small RNAs in the Global Regulation of RNA Silencing. *RNA.* 2010(1):1-5.

HOFFMANN S, OTTO C, KURTZ S, SHARMA C, KHAITOVICH P, STADLER PF *et al.* Fast Mapping of Short Sequences with Mismatches, Insertions and Deletions Using Index Structures. *PLoS Comp Biol.* 2009;5(9):1-10.

JOHNSON DS, MORTAZAVI A, MYERS R, WOLD B. Genome-wide Mapping of *in vivo* Protein-DNA Interactions. *Science.* 2007;316(5830):1497-1502.

KIRCHER, M, KELSO, J. High-throughput DNA Sequencing –Concepts and Limitations. *Bioessays.* 2010;32:524-536.

LANGENBERGER D, BERMUDEZ-SANTANA C, HERTEL J, HOFFMANN S, KHAITOVICH P, STADLER PF. Evidence for Human MicroRNA-offset RNAs in Small RNA Sequencing Data. *Bioinformatics.* 2009;25:2298-2301.

LANGENBERGER D, BERMUDEZ-SANTANA C, STADLER PF, HOFFMANN S. Identification and Classification of Small RNAs in Transcriptome Sequence Data. *Pac Symp Biocomput.* 2010;80-87.

LI R, LI Y, KRISTIANSEN K, WANG J. SOAP: Short Oligonucleotide Alignment Program. *Bioinformatics.* 2008;24:713-714.

LI H, RUAN J, DURBIN R. Mapping Short DNA Sequencing Reads and Calling Variants Using Mapping Quality Scores. *Genome Res.* 2008;18:1851-1858.

MARGULIES M, EGHOLM M, ALTMAN W, ATTIYA S, BADER J, BEMBEN L, *et al.* Genome Sequencing in Microfabricated High-density Picolitre Reactors. *Nature.* 2005;437(7057):376-380.

MARIONI J, MASON C, MANE S, STEPHENS M, GILAD Y. RNA-seq: An Assessment of Technical Reproducibility and Comparison with Gene Expression Arrays. *Genome Res.* 2008;18(9):1509-1517.

METTE MF, VAN DER WINDEN J, MATZKE AJ, AUFSATZ W, MATZKE M. RNA-directed DNA Methylation in Arabidopsis. *Proc Natl Acad Sci U S A.* 2002;99(NIL):16499-16506.

MOROZOVA O, HIRST M, MARRA M. Applications of New Sequencing Technologies for Transcriptome Analysis. *Annu Rev Genomics Hum Genet.* 2009;10:135-151.

MORTAZAVI A, WILLIAMS B, MCCUE K, SCHAEFFER L AND WOLD B. Mapping and quantifying mammalian transcriptomes by RNA-Seq. *Nat Methods.* 2008;5(7):621-8.

NAPOLI C, LEMIEUX C, JORGENSEN R. Introduction of a Chimeric Chalcone Synthase Gene into Petunia Results in Reversible Co-Suppression of Homologous Genes in trans. *Plant Cell.* 1990;2(4):279-289.

SANGER F, COULSON AR. A Rapid Method for Determining Sequences in DNA by Primed Synthesis with DNA Polymerase. *J Mol Biol.* 1974;94:441-448.

SANGER F, AIR GM, BARRELL BG, *et al.* Nucleotide Sequence of Bacteriophage phiX174 DNA. *Nature*. 1977;265:687-695.

SCHENA M, SHALON D, DAVIS RW, BROWN PO. Quantitative Monitoring of Gene Expression Patterns with a Complementary DNA Microarray. *Science*, 1995; 270:467-470.

SCHUSTER SC. Next-generation sequencing Transforms Today's Biology. *Nat methods*. 2008;5(1):16-18.

SHENDURE J, PORRECA G, REPPAS N, LIN X, MCCUTCHEON JP, ROSENBAUM A, *et al.* Accurate Multiplex Polony Sequencing of an Evolved Bacterial Genome. *Science*. 2005;309(5741):1728-1732.

SMITH LM, SANDERS JZ, KAISER RJ, *et al.* Fluorescence Detection in Automated DNA Sequence Analysis. *Nature*. 1986;321:674-679.

STRAUSBERG R, LEVY S. Promoting transcriptome diversity. *Genome Res*. 2007;17(7):965-968.

SWERDLOW H, GESTELAND R. Capillary Gel Electrophoresis for Rapid, High Resolution DNA Sequencing. *Nucleic Acids Res*. 1990;18:1415-1419.

TANZER A, RIESTER M, HERTEL J, BERMUDEZ-SANTANA C, GORODKIN J, HOFACKER I, STADLER PF. Evolutionary Genomics of MicroRNAs and Their Relatives: En: *Evolutionary Genomics and Systems Biology*, G. Caetano Anolles, eds. Wiley-Blackwell, Hoboken NJ; 2010. p. 295-327

VELCULESCU VE, ZHANG L, VOGELSTEIN B, KINZLER KW. Serial Analysis of Gene Expression. *Science*. 1995;270:484-487.

WANG, Z, GERSTEIN M, SNYDER M. RNA-Seq: A Revolutionary Tool for Transcriptomics. *Nature Reviews Genetics*. 2009 ;10, 57-63.

ZHAO Q, CABALLERO O, LEVY S, STEVENSON B, CSELI C, DE SOUZA S *et al.* Transcriptome Guided Characterization of Genomic Rearrangements in a Breast Cancer Cell Line. *Proc Natl Acad Sci U S A*. 2009;106(6):1886-1891.