

**DESCUBRIMIENTO DE PEQUEÑOS MARCOS DE
LECTURA EN EL CROMOSOMA 2 DE DROSOPHILA
MELANOGASTER**

Trabajo final de la alumna

Pamela Magjor

Este trabajo ha sido presentado como requisito para la obtención del título
de
Licenciada en Genética

Carrera: Licenciatura en Genética

Escuela de Ciencias Agrarias, Naturales y Ambientales
Universidad Nacional del Noroeste de la Provincia de Buenos Aires

Pergamino, 20 de diciembre de 2011

**DESCUBRIMIENTO DE PEQUEÑOS MARCOS DE
LECTURA EN EL CROMOSOMA 2 DE DROSOPHILA
MELANOGASTER**

Trabajo final de la alumna

Pamela Magjor

Este trabajo ha sido presentado como requisito para la obtención del título
de
Licenciada en Genética

Director: Rolando Rivera Pomar

Carrera: Licenciatura en Genética

Escuela de Ciencias Agrarias, Naturales y Ambientales.
Universidad Nacional del Noroeste de la Provincia de Buenos Aires

Pergamino, 20 de diciembre de 2011

AGRADECIMIENTOS

A todas las personas que participaron haciendo posible este proyecto, muchas gracias por su apoyo y enseñanza:

A Rolando Rivera Pomar, director, quien siempre me guió y no dudó en ayudarme incondicionalmente cada vez que lo necesité;

A la Escuela de Ciencias Agrarias Naturales y Ambientales (ECANA) de la UNNOBA, por haber permitido realizar mis estudios y lograr mi formación;

A la Comisión de Investigaciones Científicas (CIC), por darme la posibilidad y el sustento necesarios para realizar este trabajo;

A todos mis profesores y compañeros que fueron fundamentales en este camino;

A Elin, por ser mi compañera y cómplice en las dificultades que se me presentaban;

A mi mamá, mi hermana y mi sobrino, por su apoyo en esta tesis y en toda mi vida;

A Walter, por su infinita paciencia y su fiel compañía;

A mis amigos, que me soportaron y acompañaron;

A mis familiares, por estar siempre que los necesito.

Nota

Los resultados presentados en este trabajo final fueron parte del siguiente trabajo científico: Diambra, L., Ons, S., Gutiérrez, P., Gennero, E., Magjor, P., Rivera-Pomar, R., Genomic analysis of polycistronic transcripts in insects, Sixth International Symposium on Molecular Insect Science, Amsterdam, Holanda, Octubre 2011.

INDICE

Introducción.....	Página 5
Genómica.....	Página 5
ORFs y sORFs.....	Página 9
Razones para analizar a <i>Drosophila melanogaster</i>	Página 17
Hipótesis.....	Página 20
Objetivo.....	Página 20
Materiales y métodos.....	Página 21
Herramientas bioinformáticas.....	Página 21
Bases de datos.....	Página 21
BLAST.....	Página 21
Augustus.....	Página 22
Resultados.....	Página 23
Análisis de nuevos genes correspondientes a regiones genómicas no anotadas y con estructura predicha.....	Página 27
Regiones genómicas con validación tanto por ESTs como por espectrometría de masas.....	Página 27
Regiones genómicas con validación sólo por espectrometría de Masas.....	Página 79
Discusión y conclusiones.....	Página 136
Bibliografía citada.....	Página 139
Resumen.....	Página 140
Anexos.....	Página 141

INTRODUCCIÓN

GENÓMICA

El genoma es el complemento genético entero y haploide de un individuo. Es decir, toda la secuencia de ADN (ácido desoxirribonucleico) de un organismo. Define las características de cada ser vivo, ya que cada individuo se distingue por su material genético. Por lo general, al hablar de genoma en los seres eucarióticos nos referimos sólo al ADN contenido en el núcleo, organizado en cromosomas, aunque también las mitocondrias y los cloroplastos contienen genes.

Un genoma incluye genes que codifican productos proteicos y ARNs (ácido ribonucleico), pseudogenes, los cuales representan secuencias nucleotídicas similares a un gen normal que derivaron por duplicación y posterior divergencia de un gen funcional pero sin capacidad de producir una molécula de ARN o una proteína funcional, es decir, sin expresión (1). Se creía que los pseudogenes eran “fósiles genéticos” que quedaron de un momento en la evolución del genoma en la que pueden haber tenido una función importante, hoy perdida. Sin embargo, nuevas evidencias indican que pueden funcionar como elementos reguladores. Se ha determinado en levaduras que el genoma se transcribe de manera masiva tanto en una como en otra hebra de ADN. Esto se denomina transcripción difusa (pervasive transcription) e implica que se transcriben muchos más ARNs que los esperados como codificantes. Esto llevó al concepto de ARN no codificador (ARNnc), algunos de los cuales son pseudogenes con función regulatoria. Para mas detalles, ver (www.pervasivetranscription.com).

Otros elementos genéticos que podemos encontrar en un genoma son los orfones, los cuales constituyen secuencias de ADN solitarias y dispersas por el genoma de un organismo que derivan de familias multigénicas en tandem; por tanto el orfón es una

secuencia de ADN que ha perdido su familia (2). También encontramos en un genoma regiones no codificantes, las cuales pueden ser regulatorias o estructurales.

Para estudiar un genoma es necesario realizar un mapeo genético, un mapeo físico y una secuenciación exhaustiva. El mapeo genético se basa en el uso de técnicas genéticas, como experimentos de recombinación y estudios de pedigrees, para construir mapas que muestren la posición de diferentes marcadores genéticos. El mapeo físico utiliza técnicas de Biología Molecular para examinar directamente las moléculas de ADN para la construcción de mapas que muestran la posición de fragmentos de ADN (en general de secuencia desconocida) en el genoma.

Como no es posible aún secuenciar un genoma en una sola reacción de secuenciación se lo divide en fragmentos, los cuales se almacenan en forma de clones en bibliotecas genómicas. Una biblioteca genómica es un conjunto de clones, cada uno de los cuales contiene un fragmento del genoma de un organismo dado. Las bibliotecas genómicas se obtienen clonando los fragmentos del genoma de un organismo en vectores plasmídicos. La genómica es una disciplina moderna que permite estudiar el ADN en diferentes niveles (desde un gen individual hasta el complemento genético completo de un organismo), es decir, se ocupa de caracterizar los genomas. Se divide en Genómica Estructural y Genómica Funcional. La Genómica Estructural tiene como objetivo conocer los genomas de diferentes especies y determinar los genes contenidos en él, así como las secuencias regulatorias; la Genómica Funcional determina las funciones e interrelaciones de los genes con respecto a procesos celulares específicos. Cuando la secuencia de un genoma es determinada completamente y cada gen es anotado (es decir, es asignada una identificación tentativa), se pueden agrupar genes de acuerdo a procesos en los que participa la presunta proteína codificada por el gen (por ejemplo, síntesis de

ADN, síntesis proteica) con lo cual se establece que cada fracción del genoma está asociada a actividades celulares determinadas.

El objetivo de la anotación genómica es predecir genes, secuencias promotoras y reguladoras de la expresión, y definir su función en el contexto del genoma entero. Por otro lado, la genómica implica la comparación de genomas de distintos individuos de la misma especie para detectar polimorfismos, y comparar genomas de individuos de diferentes especies para proveer datos evolutivos. A mayor similitud entre genomas, mayor cercanía evolutiva entre dichos organismos comparados. Este procedimiento se denomina filogenia molecular derivada de secuencias génicas o filogenómica. Las comparaciones genómicas apoyan conclusiones basadas en dos décadas de investigación sobre genes que se han conservado durante cientos de millones de años. Debido a la conservación de genes y proteínas, los resultados de experimentos en un organismo son guías útiles para investigar en otros organismos.

Los proyectos de secuenciación genómica han expandido el conocimiento sobre la estructura y organización del genoma y han ofrecido un desafío para identificar genes funcionales en dichos genomas. La combinación de la secuenciación genómica y de algoritmos computacionales de hallazgo de genes produjo el inventario de una gran parte de los genes codificantes de proteínas para diferentes organismos. Las funciones de la mitad de las proteínas codificadas son conocidas o se produjeron por medio de comparación de secuencias pero muchos genes y proteínas aún esperan ser identificados. Asimismo aún no se ha establecido un método certero que permita determinar con precisión el número de genes. De hecho, los métodos de predicción informáticos varían en función del algoritmo usado y también varían en función del método de análisis. Como ejemplo podemos mencionar la primera aproximación basada en el borrador del genoma humano: algunos predijeron 35.000 a 120.000 genes (3).

La determinación de la secuencia completa del genoma de varios organismos reveló variaciones en el número de genes codificantes de proteínas y en su organización en procariotas y eucariotas. La disposición más frecuente de genes codificantes de proteínas en los procariotas tiene una lógica notable: los genes dedicados a un único objetivo metabólico se suelen encontrar en una disposición contigua en el ADN. Tal disposición de genes en un grupo funcional se denomina operón porque opera como una unidad a partir de un único promotor. La transcripción de un operón produce una hebra continua de ARN mensajero que transporta el mensaje para una serie relacionada de proteínas. Cada secuencia del ARN mensajero representa la unidad o gen que codifica una de las proteínas en la serie. En el ADN procariante, los genes están estrechamente empaquetados, con muy pocos intervalos no codificadores, y el ADN se transcribe en ARN mensajero colineal (policistrónico), que luego es traducido a proteína.

En cambio, los genes eucariontes dedicados a una única vía están habitualmente separados físicamente en la hebra de ADN y suelen localizarse en distintos cromosomas. Cada gen se transcribe a partir de su propio promotor, produciendo un ARN mensajero, que generalmente es traducido para producir un único polipéptido. Se cree que los organismos eucariontes también podrían incluir ARN mensajeros policistrónicos codificantes de pequeños péptidos (genes no canónicos), ya que los ejemplos conocidos son muy pocos y sin confirmación funcional, tal como se explica en párrafos siguientes. El análisis de este tipo de genes es uno de los objetivos de este trabajo.

Las secuencias genómicas deben ser descriptas y organizadas de una manera confiable y actualizada, para poder obtener información útil a partir de ellas. A este proceso se lo denomina anotación. En el proceso de anotación se utilizan diversas fuentes, entre las cuales están: publicaciones que reportan nuevas secuencias, revisiones que actualizan

periódicamente la anotación de familias o grupos de proteínas, expertos externos y análisis de secuencias. Estos se complementan con la predicción bioinformática de marcos de lectura codificantes y en la predicción de las uniones de exones e intrones.

Sin embargo esto presenta limitaciones dadas por la escasa información disponible, en cuanto al número de organismos secuenciados. Un genoma anotado incluye, además de la secuencia, una descripción de la probable función de cada producto génico, la cual se deduce de comparaciones con otras secuencias genómicas y con funciones proteicas establecidas.

ORFs y sORFs

Se denomina marco abierto de lectura (ORF, del inglés *Open Reading Frame*) a cada una de las secuencias de ADN comprendida entre un codón de inicio (ATG) de la traducción y un codón de terminación, descontando las secuencias que corresponden a los intrones en caso de haberlas. Se encuentra acotado por los UTRs (secuencias no traducidas). Un ORF se define por métodos bioinformáticos en secuencias que suelen contener al menos 100 codones. Esto excluye a proteínas conocidas y con menos de 100 aminoácidos, como podría ser la insulina. Esto revela las limitaciones de los métodos empleados al día de hoy y es motivo también del estudio presentado en este trabajo final.

En una secuencia de ADN cualquiera hay, *a priori*, 6 posibles sentidos en los que pueden aparecer marcos abiertos de lectura; dado que cada codón está formado por 3 nucleótidos, existen 3 posibles lugares de inicio para tomar los nucleótidos de 3 en 3. A lo que hay que sumar los otros 3 posibles marcos abiertos de lectura si el ADN es traducido tomando como molde la hebra complementaria, dando el sentido de lectura

opuesto. Estos marcos abiertos de lectura se denominan +1, +2, +3, -1, -2 y -3, respectivamente.

El número de genes que codifican proteínas en eucariotas superiores identificados por proyectos de genoma es más bajo que lo esperado, mientras que ha sido detectada una considerable cantidad de transcriptos putativamente no codificantes. Esto refleja, nuevamente, las limitaciones de los sistemas predictivos. Pero en caso de ser correctas, ¿cómo es posible que la enorme variabilidad fenotípica de los organismos tenga como origen un pequeño número de genes mayormente conservados? Varias respuestas han sido propuestas: interacciones génicas complejas, splicing alternativo, y genes no codificantes. Otra posibilidad menos discutida podría ser muchos genes no canónicos y por lo tanto no identificados, escapen a la detección de los programas de anotación génica.

Algunos métodos de detección génica y anotación permiten encontrar genes con sORFs (pequeños marcos abiertos de lectura, del inglés *small open reading frames*) que codificarían pequeños péptidos, los cuales esperan caracterización. Alguno de estos, sin embargo, son anotados en base a similitudes encontradas entre organismos a partir de péptidos que fueron caracterizados antes de la secuenciación del genoma, como por ejemplo, las histonas, la insulina, la RNAsa, todos ellos con menos de 100 aminoácidos.

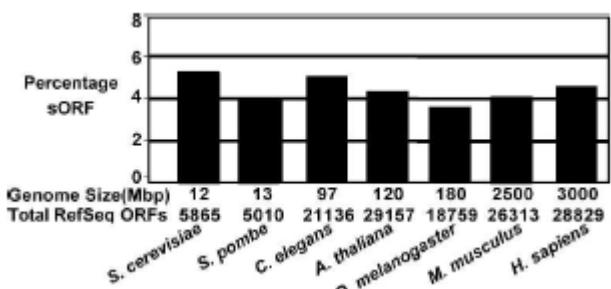
Aquellos sORFs menores a 100 aminoácidos correspondientes a genes funcionales pueden escapar a la detección debido a que se consideran sORFs sin sentido formados por azar.

Es sabido que péptidos pequeños pueden tener funciones biológicas importantes, mayoritariamente en la comunicación neural y endócrina, pero, en todos estos casos descriptos, los péptidos son productos maduros clivados de un ORF más largo.

El genoma secuenciado y anotado inicialmente de *Saccharomyces cerevisiae*, tuvo en cuenta todos los ORFs de al menos 100 codones contiguos no contenidos dentro de un ORF más largo. El primer estudio funcional de sORFs se realizó utilizando como modelo a *Saccharomyces cerevisiae* (4). En esta investigación, se realizaron diferentes experimentos y análisis computacionales, hallándose evidencia de 299 sORFs en el genoma de *Saccharomyces cerevisiae*, lo cual representa el 5 por ciento de los ORFs anotados. Estos experimentos representaron la primera evidencia de la transcripción de cientos de marcos de lectura no anotados en *Saccharomyces cerevisiae*, incluyendo muchos sORFs. Uno de los experimentos realizados consistió en crear colecciones de cepas de delección génica haploides, en las cuales se eliminaban diferentes sORFs. Las delecciones dieron como resultado un fenotipo letal o de crecimiento lento, lo cual indica que la función dada por estos sORFs es esencial. Uno de esos sORFs fue caracterizado, y se determinó que es un blanco downstream de la vía mediada por MEC-1, la cual regula la detención del daño en el ADN y de la replicación. Estos resultados validaron la significancia funcional de sORFs, y sugieren que otros sORFs pueden tener funciones importantes. Además, se determinó un porcentaje similar de sORFs anotados en otros eucariotas (Figura 1), y 184 de los sORFs de *Saccharomyces cerevisiae* exhiben similitud con ORFs en otros organismos, de lo cual se desprende que sORFs están conservados en otros organismos y tienen funciones biológicas importantes.

En este trabajo final aplicamos una serie de métodos bioinformáticos que nos ha permitido descubrir cientos de potenciales nuevos genes que codifican sORFs, con la posibilidad de que puedan existir varios miles. En *Populus deltoides* se identificaron sORFs que codifican péptidos, los cuales se encuentran conservados entre *P. deltoides* y otras 14 especies de plantas, sugiriendo la conservación interespecífica de dichos sORFs (5). Estos números están en línea con estimaciones realizadas en otros eucariotas,

Figura 1: sORFs constituyen un porcentaje similar de ORFs anotados en eucariotas representativos

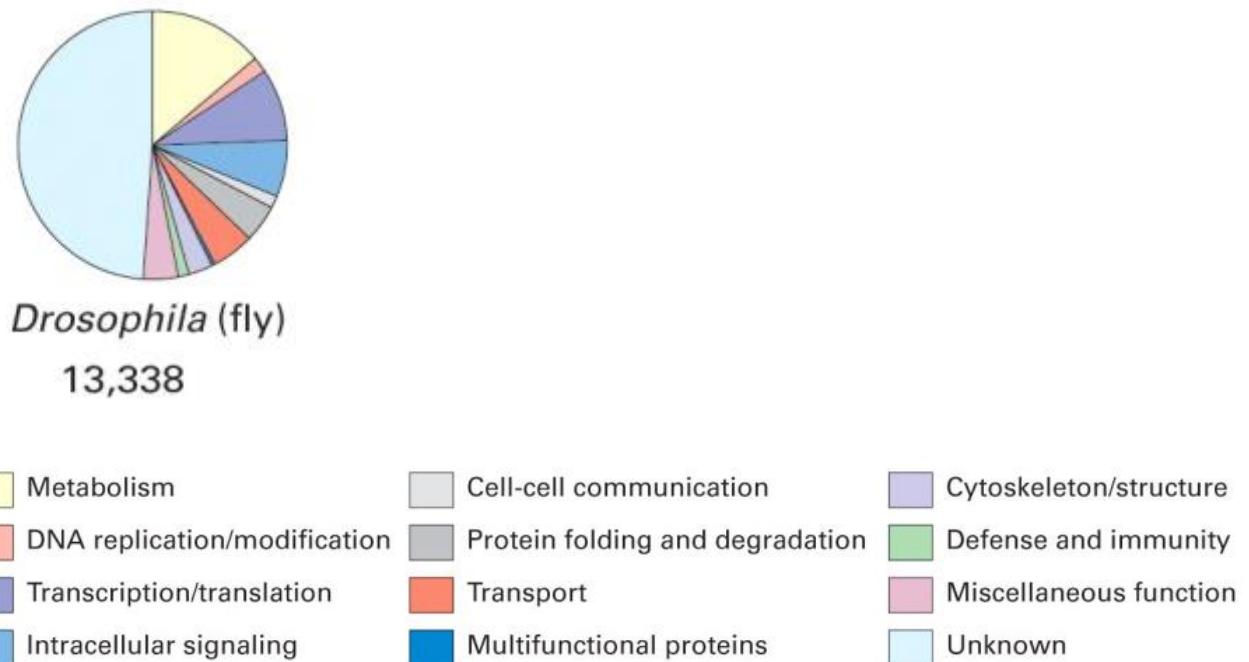


Tomado de Kastenmayer James P. et al., Functional genomics of genes with small open reading frames (sORFs) in *S. cerevisiae*, 2006, Genome Research, 16:365–373 ISSN 1088-9051/06.

sugiriendo que sORFs pueden representar una fracción significativa del genoma eucariótico traducido (Figura 2).

En *Drosophila melanogaster*, se caracterizó el gen *tarsal-less* (*tal*), un nuevo tipo de gen no canónico que ha sido previamente clasificado como ARN no codificante (6). En este estudio se demostró que *tal* controla la expresión génica y la morfogénesis en *Drosophila melanogaster*. La función de *tal* es mediada por varios ORFs de 33 nucleótidos contenidos en un solo transcripto, siendo este un locus policistrónico. *tal* define dos nuevos paradigmas en los genes codificantes eucariotas: la existencia de pequeños péptidos con función biológica, y su arreglo en mensajeros policistrónicos. *tal* se identificó a través de mutantes espontáneos (*tal^l*) cuyo fenotipo era la presencia de patas defectuosas, en las cuales los segmentos del tarso no se desarrollan. La expresión de *tal* en las patas es transitoria, y coincide con la especificación de la región del tarso por activación de genes específicos en un patrón en anillos similares a *tal*. Uno de los genes activados transitoriamente en el mismo momento que *tal*, y requerido para la formación del tarso es el factor de transcripción *rotund* (*rn*), cuya expresión se pierde en mutantes *tal*, pero la pérdida de *rn* no afecta la expresión de *tal*. Estos resultados demuestran que el gen *rn* es un blanco downstream de *tal*. Expresión ectópica de *tal* induce la morfogénesis en las patas, lo cual no es producido por cambios en la expresión de *rn*, ni el fenotipo es rescatado por inducir la expresión de *rn* en mutantes *tal*. Los mutantes nulos de *tal* provocan letalidad embrionaria, demostrando que es un gen esencial.

Figura 2: número y tipos de proteínas codificadas en el genoma de *Drosophila*.



Tomado de Lodish, Biología Celular y Molecular, 5^a edición, Editorial Médica Panamericana.

Existen cinco sORFs en el transcripto *tal*. De 5' a 3' son: 1A, 2A, 3A, AA, y B. Los sORFs tipo A incluyen un motivo conservado de siete aminoácidos (LDPTGXY), el cual se encuentra fuertemente conservado en genes homólogos a *tal* en otras especies, definiendo una antigua y no canónica familia génica eucariótica. sORFs 1A y 2A codifican un péptido idéntico de once aminoácidos. sORF 3A codifica otro péptido de once aminoácidos muy similar a 1A. sORF AA codifica un péptido de treinta y dos aminoácidos. sORF B codifica un péptido de cuarenta y nueve aminoácidos sin dominios conservados en otros insectos.

Para interpretar el rol de cada sORF, se realizó una construcción químérica que sólo llevaba un sORF tipo A más un sORF B, lo cual fue completamente funcional. Otros dos constructos en los cuales se impidió la traducción del sORF B, ya sea por su delección o por mutación de su codón de comienzo de la traducción, dio como resultado una completa funcionalidad de *tal*. Asimismo, una construcción con un solo tipo de sORF A es completamente funcional. Con esto se desprende que un solo tipo de sORF A es suficiente para proveer la función de *tal*, y que sORF B no es necesario para dicha función.

Los péptidos de 11 aminoácidos codificados por *tal* provocan una señal celular que participa en el desarrollo de la pata de *Drosophila* (7). Esta señal alcanza 2 a 3 células es atribuida a la acción directa de los péptidos *tal*. Durante el desarrollo de la pata, *tal* señaliza una actividad que determina el límite del tarso, el cual regula la transcripción de varios genes, lo que indicaría que *tal* actúa de manera no autónoma. Esta señal producida por *tal* regula los genes *rotund* (*rn*) y *spineless* (*ss*), y crea un límite requerido para la intercalación, crecimiento y supervivencia de los segmentos dos, tres y cuatro del tarso. Estudios de pérdida de función y de expresión ectópica demuestran que *tal* es requerido de forma no autónoma para el desarrollo del tarso. A nivel molecular,

los péptidos codificados por el gen *tal* cambian la actividad de regulador transcripcional del gen *shavenbaby* (*svb*). El locus *svb* codifica tres isoformas proteicas solapantes: *svb* y las proteínas específicas de la línea germinal OvoA y OvoB. Todas estas proteínas comparten el mismo sitio de reconocimiento del ADN y de activación transcripcional, pero difieren en su amino-terminal. La isoforma más corta, OvoB, es un activador transcripcional que induce la formación de tricomas. OvoA contiene una región amino-terminal extendida, lo cual cambia la función hacia un represor transcripcional, inhibiendo la formación del tricoma. Svb contiene una mayor extensión, comparado con OvoA, y promueve la formación de tricomas. *tal* no tiene efecto sobre la isoforma más corta (OvoB), sino que controla específicamente la capacidad de Svb de inducir tricomas, sin influir en su producción ni en su transporte al núcleo sino que modifica la actividad del producto génico, que pasa de ser un represor a un activador, controlando así la diferenciación epidérmica y de tricomas en *Drosophila* (8).

Homólogos a la familia *tal* se identificaron en artrópodos, conteniendo sORFs homólogos de entre 10 y 13 codones, los cuales son traducidos en péptidos que funcionan durante el desarrollo. Esos datos muestran que genes funcionales que codifican muy pequeños ORFs pueden existir en otros eucariotas superiores.

Los sORFs no encajan con la definición estándar de gen, no son considerados en la anotación de genomas y caen, finalmente, en regiones consideradas como no informacionales. Sin embargo, los sORFs podrían tener un rol en muchos procesos biológicos, modulando el flujo de información de una manera aún impredecible. Pero para esto necesitan ser identificados como una parte funcional del genoma, tal como hemos hecho en este trabajo.

Debido a su cuidadoso análisis genómico y la cantidad de información disponible, el de *Drosophila* es uno de los mejores genomas anotados y, aún así, una fracción importante

de sORFs podría haber escapado a la detección por parte de métodos de anotación que se han aplicado.

RAZONES PARA ANALIZAR A *DROSOPHILA MELANOGASTER*

Thomas Hunt Morgan introdujo el empleo de la mosca de la fruta, *Drosophila melanogaster*, en la investigación genética. Desde entonces se ha transformado en uno de los organismos modelo más usado en diversas disciplinas científicas. Entre las ventajas que ofrece su uso se destacan las siguientes:

- ✓ Fácil de criar, de manipular, requiere poco espacio y su costo es reducido.
- ✓ La embriogénesis se completa en 24 horas a 25 grados centígrados.
- ✓ El ciclo de vida es corto (9-10 días a 25° C).
- ✓ El genoma, completamente secuenciado, se resume en cuatro cromosomas.
- ✓ Se dispone de amplias colecciones de líneas mutantes accesibles a la comunidad científica.
- ✓ Es considerado el mejor modelo de eucariota superior para realizar estudios genómicos, transcriptómicos y proteómicos.

El complemento cromosómico de *Drosophila melanogaster* consta de 4 parejas de cromosomas: los cromosomas sexuales X e Y (cromosoma I) y 3 parejas de autosomas (II, III, IV). Los cromosomas Y y IV son pequeños y telocéntricos, siendo el cromosoma Y heterocromático y portador de algunos genes relacionados con la espermatogénesis. La mayoría de los genes se localizan en los cromosomas X, II y III, que son metacéntricos y grandes. Es en uno de estos cromosomas en los cuales se desarrolla este trabajo.

Su desarrollo (Tabla 1) incluye un período de embriogénesis dentro del huevo y una sucesión de estadios larvales que culminan con una metamorfosis completa (holometábolos), de la que finalmente surge un adulto. El desarrollo se completa en 10 días a 25° C y 60 % de humedad relativa. Del huevo una pequeña larva (primer estadio), la cual muda al cabo de un día y llega al último estadio larval en el tercer día. Durante la metamorfosis, la hormona ecdisona desencadena una serie de cambios en el organismo entre los cuales se cuentan la destrucción de ciertos tejidos y órganos larvarios (histólisis) y la organización de las estructuras del adulto a partir de los discos imaginarios y de células larvarias que se diferencian. El estado pupal lleva 3 a 5 días del ciclo hasta la emergencia del adulto.

Tabla 1: Cronología del desarrollo de *Drosophila melanogaster* a 25°C (tomada de la guia de trabajos practicos de genetica, FCNyM, UNLP)

Por día	Por hora	Fase
0	0	Huevo depositado
0-1	0-22	Embrión
1	22	Eclosión del huevo (primer estadio larval)
2	47	Primera muda (segundo estadio larval)
3	70	Segunda muda (tercer estadio larval)
5	118	Formación del pupario
5	122	Muda “prepupal” (cuarto estadio)
5.5	130	Pupa: eversión de cabeza, alas y patas
5.7	167	Pigmentación de ojos pupales
9	214	Adulto emerge del pupario con alas plegadas
	215	Las alas se expanden al tamaño adulto

HIPÓTESIS

1. El genoma de *Drosophila melanogaster* tiene genes no identificados aún en regiones consideradas no codificantes.
2. Los organismos eucariontes expresan transcriptos policistrónicos de una zona más amplia que lo esperado.

OBJETIVO

Analizar el genoma del cromosoma 2 de *Drosophila melanogaster* en busca de sORFs codificados en ARNs policistrónicos.

MATERIALES Y MÉTODOS

HERRAMIENTAS BIOINFORMÁTICAS

BASES DE DATOS

La secuencia correspondiente al cromosoma 2 de *Drosophila melanogaster* se obtuvo por FTP a partir de las bases de datos públicas (National Center for Biotechnological Information, NCBI, Flybase y Ensembl). Los mismos fueron obtenidos en formato Fasta y trabajados con formato de texto usando un algoritmo (no publicado) desarrollado en la base Wolfram Mathematica por el Dr. Luis Diambra del Laboratorio de Biología de Sistemas, Centro Regional de Estudios Genómicos, Universidad Nacional de La Plata y cedido gentilmente para nuestros análisis. Se detalla en la sección de resultados el diagrama de flujo de análisis y los datos obtenidos.

BLAST

El programa de computación empleado con el propósito de comparar secuencias es BLAST (basic local alignment search tool). El algoritmo BLAST divide la secuencia de la nueva proteína o gen (secuencia consultada o *query*) en segmentos más cortos y luego busca en la base de datos coincidencias significativas con cualquiera de las secuencias almacenadas. El programa de coincidencias asigna un puntaje alto a los aminoácidos que coinciden idénticamente y un puntaje más bajo a coincidencias entre aminoácidos que son relacionados (por ejemplo, hidrófobos, polares). Cuando se encuentra una coincidencia significativa para un segmento, el algoritmo BLAST buscará localmente para extender la región de similitud. Una vez completada la búsqueda, el programa clasifica las coincidencias entre la secuencia de averiguación y diversas proteínas

conocidas de acuerdo con sus valores p . Este parámetro es una medida de la probabilidad de hallar ese grado de similitud entre dos secuencias de proteínas por casualidad. Mientras más bajo es el valor p , mayor es la similitud de secuencias entre dos secuencias. Un valor menor de 10^{-3} es una evidencia significativa de que dos proteínas comparten un ancestro común.

En este trabajo utilizamos específicamente el programa tBLASTn, el cual busca coincidencias entre la secuencia peptídica ingresada y una base de datos de nucleótidos, cuyas secuencias son traducidas en los 3 marcos de lectura posibles sobre ambas cadenas del ADN dúplex. Esta búsqueda se realizó utilizando los parámetros que ofrece el programa por default, con un valor $E=10^{-3}$.

AUGUSTUS

Augustus Gene Prediction es una herramienta de predicción génica eucariótica que emplea un método adecuado para modelar la distribución en longitud de exones e intrones. Provee información sobre las secuencias nucleotídicas de los exones e intrones, y sobre las secuencias peptídicas. Puede ser utilizado a través de una interface web (<http://augustus.gobics.de/>) o descargado y utilizado localmente.

RESULTADOS

Por medio de una aproximación bioinformática se identificaron sORFs en el cromosoma 2 de *Drosophila melanogaster* utilizando un algoritmo que detecta sORFs policistrónicos que codifican péptidos menores a 5 kilodaltons (ver métodos). El número total de genes con potencial ORF corresponde a varios miles. Para acotar la búsqueda a un número menor, se limitó el análisis a aquellos sORFs que se encontraran en grupos de secuencia similar y menos de 2 kilobases de distancia entre cada uno. El cromosoma 2e de *Drosophila* se dividió entonces en segmentos que contenían 242 clusters de sORFs. Este análisis se acopló a un algoritmo que realiza una vinculación de la masa teórica de dichos péptidos a bancos de datos públicos de espectros de masas (www.flybase.org). Aquellos péptidos para los cuales se obtuvieron evidencias de codificación de los sORFs con espectros de masa en dichos bancos se utilizaron para realizar una búsqueda contra bases de datos de nucleótidos traducidos (tBLASTn). Los péptidos para los que no se encontraron resultados en las bases de datos (158 sORFs) fueron tomados para analizar su secuencia génica con el software Augustus. Este software determina la posible estructura del gen (su organización en exones e intrones) y predice las secuencias de aminoácidos. Dichas secuencias predichas son analizadas utilizando FlyBase para poder determinar si dichos genes estaban previamente anotados. Esto permitió descartar una serie de genes que poseían sORFs, pero dentro de ORFs más grandes. Esto no significa que estos sORFs no fueran funcionales (podrían funcionar como genes-dentro-de-genes), sino que representa un criterio de simplificación de la búsqueda. Los genes que evidenciaron no haber sido anotados previamente y que poseen una estructura génica coherente predicha por el software Augustus (33 sORFs), fueron evaluados teniendo en cuenta los pequeños péptidos

codificados por los diferentes sORFs, su evidencia en espectros de masas, y su evidencia de expresión a partir de bases de datos de ESTs (etiquetas de secuencia expresada, del inglés *Expressed Sequence Tags*) obtenida también de bases de datos públicas (NCBI: www.ncbi.nlm.nih.gov). Estos datos permitieron evaluar la transcripción y traducción de los sORFs, es decir su expresión. Se toman en cuenta los genes no anotados porque el objetivo de este trabajo es descubrir nuevos sORFs. Los nuevos genes finalmente anotados fueron 48. Los genes no anotados o aquellos sin estructura predecible fueron 77. La ausencia de predicción de estos últimos no implica que no sean expresados, pero en ese caso podrían considerarse como ncRNAs. En los párrafos subsiguientes se describen los nuevos genes encontrados en el cromosoma 2 clasificados en aquellos que muestran evidencia de transcripción y traducción y aquellos que evidencian una u otra.

Figura 3: Diagrama de flujo del análisis de anotación genómica del cromosoma 2 de *D. melanogaster*.

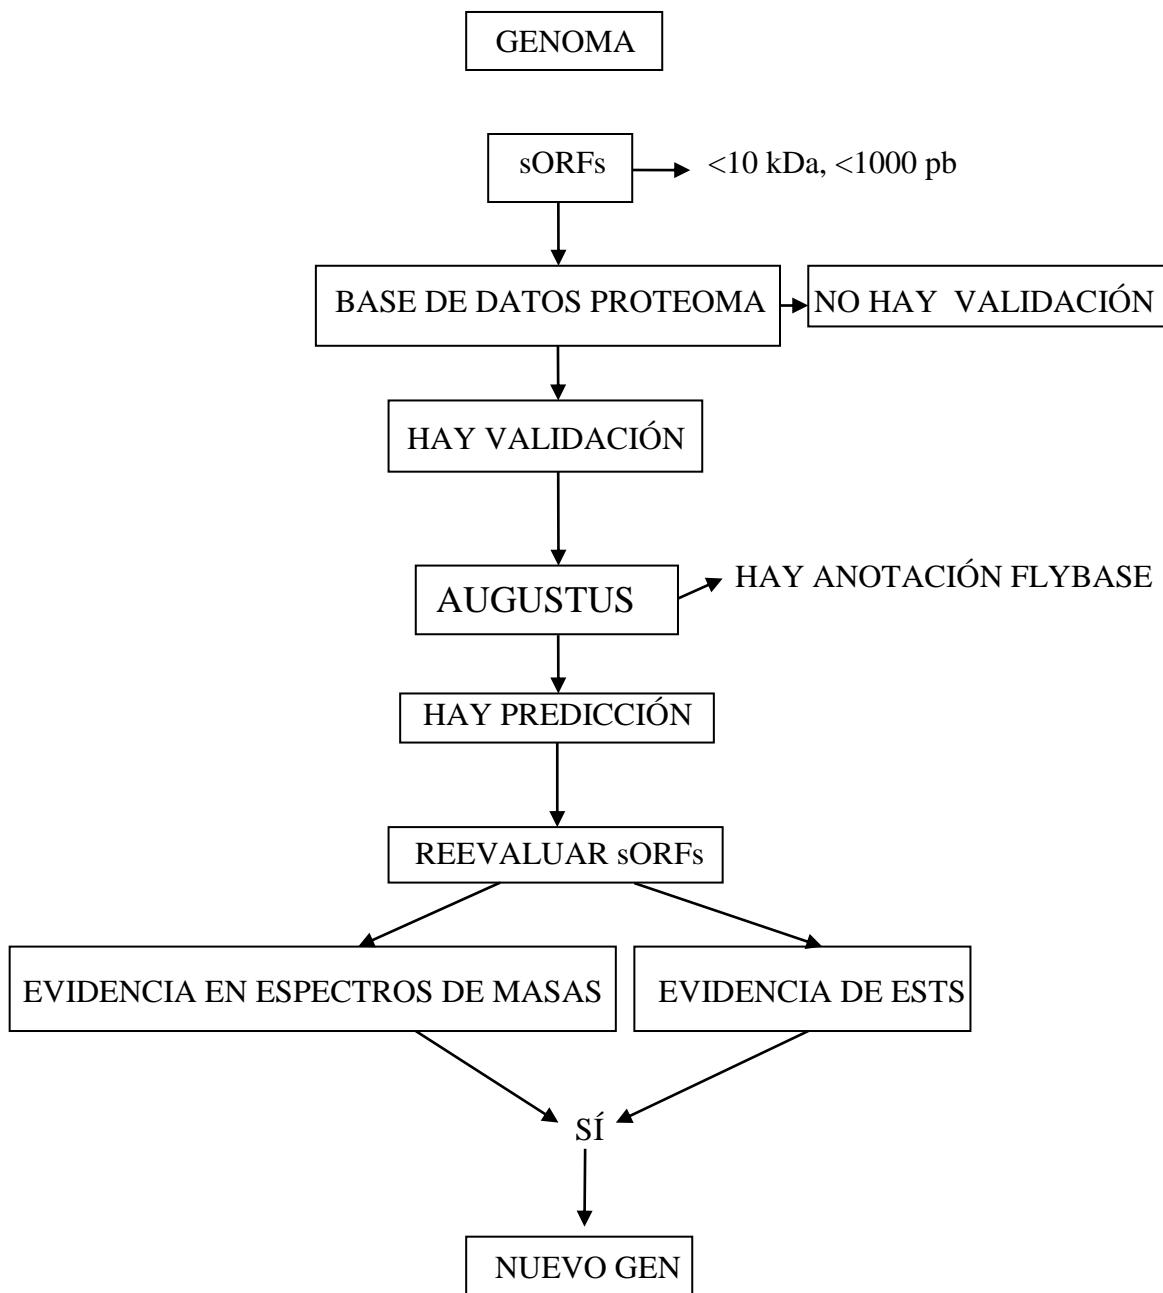


Tabla 2. Presenta los resultados obtenidos a partir de la búsqueda bioinformática descripta anteriormente:

BRAZO CROMOSÓMICO	CLUSTER S DE sORFs	CLUSTERS SELECCIONADOS	GENES ANOTADOS	GENES NO ANOTADOS	
				CON POTENCIAL ESTRUCTURAL (AUGUSTUS)	SIN ESTRUCTURA PREDECIBLE (AUGUSTUS)
2L	132	83	23	17	43
2R	110	75	25	16	34

ANÁLISIS DE NUEVOS GENES CORRESPONDIENTES A REGIONES GENÓMICAS NO ANOTADAS Y CON ESTRUCTURA PREDICHA

1. REGIONES GENÓMICAS CON VALIDACIÓN TANTO POR ESTS COMO POR ESPECTROMETRÍA DE MASAS

Gen 2L_3



```

ATTCTTAGTTGGGTCATGAGTCGTCTTAGTTGTTCTTGGTGGTTGGTCTTGT
M_S_R_L_L_S_C_C_L_L_G_G_W_F_F_C_C
CTTATGGGTTGTTCTACGAGTGGTGGCTCCCGAGTTGCCTTCAGTTGTTACCC
L_M_G_C_C_L_T_S_G_W_L_P_S_C_P_F_S_C_Y_P_L_C_S
GGCTCTAGTAGTCTTGAGCTTGACGTTTGCGAGTAGTTGGTCTCGGTAGGCTT
W_L_S_S_S_L_C_G_*
ATTCTTAGTTGGGTTATGAGTCGTCTTAGTTGTTCTATTGGTGGTGGTCTTGT
M_S_R_L_L_S_C_C_L_I_G_G_W_F_F_C_C
TTATGGGTTGTTCTACGAGTGGTGGCTCCTTGTG
L_M_G_C_C_L_T_S_G_W_L_L_C_T_G_*

```

Para la región genómica 2L_3, el programa Augustus Gene Prediction predijo una estructura compuesta por un exón de 1861 pares de bases.

Para este régión , se encontró acuerdo con espectros de masas para el péptido NMVMMVVNMLLFGGG con una probabilidad de $p=0.005$ y un valor E=0.000900377925286973.

Evidencia de EST:

gi|3946654|gb|AI297247.1|:

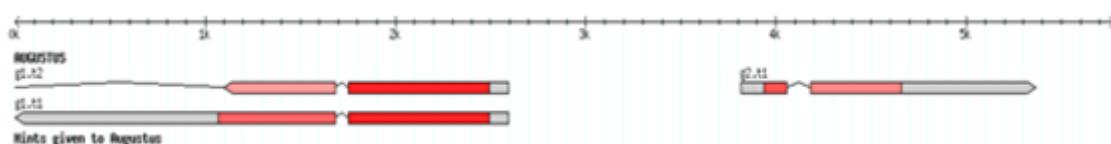
```

CTCTAGTAGTCTTGTGGTTGACGTTTGCAGTAGTTGGTCTTCGGTAGGCTTAAAGTAGTTGATT
CTTAGTTGTGGGTCATGAGTCGTCTTAGTTGTTGTCCTCTGGTGGTGGTCTCTGGTCTTA
TGGGTTGTTGCTTACGAGTGGTGGCTCCCGAGTTGCCTTCAGTTGTTACCCCTTGGTGGCT
CTCTAGTAGTCTTGTGGTTGACGTTTGCAGTAGTTGGTCTTCGGTAGGCTTAAAGTAGTTGATT
CTTAGTTGTGGGTCATGAGTCGTCTTAGTTGTTGTCCTATTGGTGGTGGTCTCTGGTCTTA
TGGGTTGTTGCTTACGAGTGGTGGCTCCTTGGTCTTCAGTTGGTCTTCAGGCTTAAAGTAGTTGATT
CTCTAGTAGTCTTGTGGTTGACGTTTGCAGTAGTTGGTCTTCGGTAGGCTTAAAGTAGTTGATT
TTAGTTGTGGGTCATGCGTTGCTTTGGTGGTGGTCTCTGGTCTTGGTCTTA
CGAGTGGTGGCTCCT

```

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 4 sORFs seguidos de una repetición en tandem de 7 sORFs idénticos, lo que podría deberse a un fenómeno de duplicación múltiple. La transcripción se basa en la presencia de un EST en la base de datos pública y la probable traducción en la presencia en bases de datos de un péptido definido por espectrometría de masas que cumpliría con los requisitos mínimos establecidos en este trabajo ($E < 0.001$) para su validación. Esto significa que al menos uno de los sORFs codificados por este transcripto es traducido. La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_4



AGCTCAGCAGCCGTTCCCGTCTCCGGCGAAAGGACCTACCAACCCAGCGAATAATGATTAGGGCCGTT
 AATCATAGAACAGTTGAAAAATAATACAACACTGTCAAAAAATACTTGTATAGTTAAGATTTAAACT
 TATTGTTAGTTCTTATACAAGAAGATTCAATAAATAAAAGCAAAGTAAAAAAAAAAAAAAAAAAAAA
 AATTCGGTTCAAGCGGGAGATGAGCACTAAATAATGCCGAAAATGCAAGCGGAGTCATGCACGTAACG
 ATATATGTAGCAATGTATGTATATGTAATGCTAGCTGCTAAACACAGCCACTATCACTTGTC
 M Y I C N A S S L K H S H Y H L S
 CAACCGATTGCGATTTAATGTATTTATTTATAATGCATGCAAATTAACACTATCACGTCGGGG
 N R L R F N V F I F I Y K C M Q I N T I T S G
 TCACCAATATTTAGCTATTGAGCTTTCAATAGCTGTTGCGAATAATAATAGCCGAAAGAAAGTTGTT
 S P I F S Y *
 TATTTACGATACTGTTATTCGCGAGTTGTTACAGCAGCTAGGGCCGACAAAGAGCTATATCGAATG
 M
 CACAAGTTAGTCTCTCCGACAGACTAAGAAGTGGCAATTGGCGGGACAGACAGCCGAAAACGCAGTG
 H K F S L F R Q T K K W Q L A G Q T A E K R S
 CCCAAGCTTAACGTAGGCTTGGCTTCAACAGAGTCCTCAAGGGGAAGCAGACACAGCTGTTCACTGCC
 A Q A *
 CGCCTTAACTCCAGACGCGGTCTCAATTCTGCAACTCGAGCGTGTGCCGTCTGCCAGGAATCAACT
 GCATGACTCTGCCAAAGGCCATCTCATTGGGGTAGATTCTCGTCCTTAACAGGAACGACGTTGTCAC
 GGCTACGCCAGGCTTAGGGTGCAGCAATTGGAGCGCTGCTGGAGTACTCTCCTCCATGCCGGCCAAA
 ATATATGCTGAAGAAAGGAGATGCGCTGACTCTGGCAAGCCGATTATAGTTAGGCCGTTATATCTG
 M L K K G D A L D S W Q A D Y S L G P L Y L
 M R L T L G K P I I V *
 GCTCGTCAAACGACGAAGGCGGACCACATTGAGAAAATGCCCGGAGTGAGGACGTCAGATCGGCAGG
 A R Q T T K A D H H * M R R S E D V Q I G R
 GTTCTCTGAATGGAACTAAAGGTGATGCTCGCTGCTGAGAAAATAACCTTCGAAGTTCAGAAGTTCA
 V L * M G T K G D A R C *

 TTTTGGCGCCGACAAAGTTGGTGGCGTTGCTGACCGAAGTTGCTTCGGCTTCCGCCGGTGCAATATGAA
 M N
 CCTCTTGAGTCGCACAGAAACACAACACTGTCGAGAGATCCTGATCAGCTCCAGGTGCACTGCCCTGGTT
 L L S P H R N T T V E R S L I S S R C T A L V
 GCAAAACATACAAATACGACAGCTACCTCAAAGCGTGAGATCCTCCAAGCGCTCATGGGAAGGTC
 CGCCATTATGTGCTCTATCAGCCGGCTTAATCCGAAACATCTGATGCACCTGTTCACGGCCTGGTA
 M C S I S R G L I R K H L M H L F T A L V
 ACCGTCTCCTCCCCAAAAGGCCAATATTGGGATCGAATTGCTCCCAGAAGAGCTCGAGGTCCGGCAT
 T V F L P P K G Q Y W D R I A P R R A R G P A
 M
 GAAGATTGCTTCATGGTAATGCGAAATAATTGCCAGAGTCACCAATGACGAATTACGGAGGCACGCC
 *
 K I A F M V M R N N C Q S H Q *
 M T N Y G G D R
 TACTCTAAGAAGTCAAATTGATCCAGGAATGGCGAGAGCGAGGATATGGGAGTAGACGAGGAAACTCTG
 L L * M G V D E E T L H Y G K A C
 CACTATGGCAAAGCATGCAACCAAGAGAATTGGGTGGTAGCAACTAGCGTCGAACGATTTGCCAC
 N Q E N F G W *
 M A K H A T K R I L G G S N *
 M Q P R E F W V V A T S V E R F L P T
 CTGAACGCCCTGGCGCATAGGTTGCCATGGCGCAATCCACGGCCTCAAAGTCCTACATCGCTGCTCCAGG
 *
 AATGCAGCCATCGATTCCCACGACGGAATAAGGTTGGCAAAGACCGAATCCTCTAACGCTCCTCCACT
 M Q P S I P T T E *
 TAGCTGGCTGCCGCATCCAGCTTGCAGCAGCACTTGCACTATGATGCAGCCAGCGATTGCTCAGT
 GGTGCCCAAACCTTCATCGCACGAATGTGAGCGTTAAACTTGTCCGACAATTCCGAAGCGATGCCACT
 M P L
 GAACCATTCCGTACTACTTAAACCCAGAATCTCGGTGATGTGCGCCTGAAAACGAAACGCCGATTAT
 N H S V L P L N P E S R *
 CAAACCTTTGAAGCAACTCTAAAGCCGCTTCGTAATTGCTGTTGAAATCTCCAATGATCGGATAGT
 TTCCAGCGCTGAATCCCTCAAACATGACCGCAGATGTTGAAATTCTCAATGTTGGAGAGGTCCGGATGG
 M T A D V E I S Q C W R G P D G C R L C S *

M_L_E_R_S_G_W
 CTGTCGATTATGCTCGTGAACACGGAGTAAAATCCGTCCAGTTGCCTAGCCTCCGCCAACGTTGGCA
 _L_S_I_M_L_V_N_T_E_*
 GCTGCACAGGCGGCAACGGCATGGCCTCGGCCGCGCTGCCTTGAGGACCACTACACTTGTGGGGCAC
 AACACCTCCGCAAGCGTAAGCGCGCGAATGCACATTGCCTTGCTATTTCGAGCGCACACTA
 GCCTTGAATTCAACGATGAATTCATCGAAAAACTCGCTCATTCACTCTCGCTGAAATCCAATTCTCCA
 GTTCTGTATGCAGAACATTGAAGGCACCTTGAGCCTCATCAATCTGCTCCAGCCTACCGTAAGAGTGGG
 TTCATCGTATCCGCTTAGCGTCTCCGCTTAGCGTCTCATGCCCTGAAACAGCGCATTGGCTTGCCTTA
 AAAAGGTCAACCTGTTTGTACACCTCAGCGGCATAGCAACAAATGCCCTTAATTGGTTCAGCGGG
 AAGATGAGCACAAAATAATGCCGAAATGCAAGCGAGTCAGCACGTAACGATATATGAGCAATGT
 ATGTATGTATATGTAATGCTAGCTCGCTAAACACAGCCACTATCAGTCCAACCGATTGCGATT
 M_Y_I_C_N_A_S_S_L_K_H_S_H_Y_H_L_S_N_R_L_R_F
 ATATGTATTATATTATTTATAATGCATGCAAATTAAACACTATCACGTCGGGTACCAATGTTAGCT
 _N_V_F_I_F_I_Y_K_C_M_Q_I_N_T_I_T_S_G_S_P_M_F_S
 ATTGAGCTTTCAATAGCTGTTGCAATAAATAGCCGAAGAAAGTTGTTGTTGTTCCCAA
 Y_*
 AAGGAAAACAGCTTATAAGACTATAATAAAAGCCACTAATAAAACTTGACCATGTTCCCCGGGAGTCC
 M_F_P_P_G_V
 TACATACTGGCCATCAGACCTAATAAGCTGCCAGACCTGATCGACTTCGCAAGTTACGAAAATATTCC
 L_H_T_G_H_Q_T_S_I_S_C_Q_T_*
 CGCAGTTGGTAAAGCTGAATGTCGCGGATCTGTCATCTGATCACTCGCTGTACTAATTACCTCC
 GCCGGTACGCAGAAAACGTGAAACCACCAATCAGATTGACCTCTAGCAAAACAAACTGGCTCAGGTATAA
 AAAATATATAAGTCACATATTGAGCTAACGCCCAAACTCAATACTGAATCTGATATAGAGAGCTGCACG
 TGTGCATTGCAATCCATCTTACTGCAGCAGCTTACTGCAACACCCAAAATAACAAATAATACAATT
 ATTCAAAAAGACCAACGTACAATCGAGCAACTCGTCCACGTAACAGCAGGAAACTGCCAACGCTCTGAAA
 CAAGAAGAGGAGCAGCATAGAGCAACTCACACCAACAGGCACAAAACAAAGTCAC
 TGTGGCGAGCCCACACTCAACTCTCGCCACCGACTGAAACGTTTGCCGATAAGGAATTCTCAGGTGG
 CTGGGCCGTAGTGTAGAAGACAGGCCACCATTTGCCGTCACCTACAAATGTGTTCACGCCAAC
 M_K_T_E_P_P_H_L_P_L_T_Y_K_M_C_S_R_Q_T
 CAGGCTACTAGCACATTGCGCTACCGCTATCCGTAACCGCCATCAGCAACACACCCAAATTGTGT
 _R_L_L_A_H_S_R_Y_R_P_I_P_*
 TTGTCCTAAAGAAATAACTAAAATAATCAAAGACAATCTCAGCCGAAAAATGCCAGCTGCACCT
 TATAACACCGGAAATGATCATCCAGCTGCCACATTCTGCAATTGCTACATAACCAAGCTTTAATACC
 ATCACTAAACTTGGTTACTTCCACACGATGGAAGAGGTGATTATCATAATGATTCAAAGCCTGGTA
 M_E_E_V_D_Y_H_N_D_S_K_A_W_*
 AGAACACACAGTCGCTCATTTACAGACCAATAAGTCACTCTCATGCAATTGAAACTATTGAA
 M_H_F_E_T_I_R_K
 ATGCCTGCTGATCCGACTTAATCAACATCTGATATATCACAATATAATCCCAGCCCACCAATTGGATT
 M_P_A_D_P_T_*
 CGCGAAAGCCATGGAACCATTGAACAGGTGAATCGTATTACAACGGAAATAAGAACTGCATTGAATATC
 GCGAATACTGTACAGCAGTATTAGACGTATCCAAGCATTGGCAGAGTCTGGCTGACGGCTAAT
 GTTAAAATTAAAACATCCCTACCGAAAGCACACACAAACTCTAAAGCTGTACCTCTATGACAGAAAG
 TTTGCAGTGGTGCAACACTGCCACTTCCACTGATCATACAATTGAGGCTGGAGTCCCCAAGGCAGCG
 TTCTGGGCCAACCTTATACCTCATCTACAGCCGACATCCCTACAAATAGTCGACATATCCACATT
 GCCGACGATAACAGCTACCTTAGCCGTTCAAGGTCCCTATCCAAGCTACAGCACAGTGGCACTGTAC
 TCATCGACATTGAGAAGTGGTCTGACTGGCGAATAAAAGTAAACGAGCAAAATGCAAGCACGTGAC
 M_Q_A_R_D
 GGTTACGCTAAACAGACAAGACTGTCCTCCGCTTATTGAACAAACATACCACTCCCAGGAAAGCAGATGAG
 G_Y_A_K_Q_T_R_L_S_S_A_L_I_E_Q_H_T_T_P_E_S_R_*
 GTAGCGTACCTAGGAGTACACCTTGACAGAACAGACTCACATGGCGCAGGCACATTGAAGCCAAAAACCC
 AACCTAAACTCAAAGCCAACAACCTACAGTGGCTCATCAACTCTGGTTCCGCTCAGCCTAGATCACAA
 GGTCTGCTCTACAATTCTATATTGAAACCAATCTGGACCTATGGCTCACAGTTATGGGGCAATGCCAG
 M_G_A_M_P
 CAACAGCAATATTGACATCATTAGCGAGCACAATCAAAGATTCTGAGAACCATCAGTGGGCACCGTGG
 A_T_A_I_L_T_S_F_S_E_H_N_Q_R_F_*
 TACGTTGGAGTGAAAACATCCAAAGAGACTTAAATATCCCATCAGTTACCAACGCAATCACGGAACTTA
 AGGAAAATACCATAGCAAGCTTCACACGCACCCAAACCACTAGCGCAGGTCTAATCCAGCTCAGCAG
 CGTTCCCGTCTCCGGCGAAAGGACCTACCAACCCAGCGAATAATGATTAGGGCCGTTAATCATAGAA
 CAGTTGGAAAATAATACAACGTGTCAAAAAAACTTGTATAGTTAAGATTTAAACTTATTGTTAGT
 TCTTATACAAGAAGATTCAATAAAAGCAAAAGTAAAAAAAAAAAAAAATTGCGTT

```

AGCGGGAAGATGAGCACTAAATAATGCCGAAAATGCAAGCGGAGTCATGCACGTAACGATATATGTAG
CAATGTATGTATGTATATGTAAATGCTAGCTCGCTTAAACACAGCCACTATCACCTGTCCAACCGATTG
M_Y_I_C_N_A_S_S_L_K_H_S_H_Y_H_L_S_N_R_L
CGATTAAATGTATTATTTATTATAAATGCATGCAAATTAAACACTATCACGTGGGGTCACCAATAT
R_F_N_V_F_I_F_I_Y_K_C_M_Q_I_N_T_I_T_S_G_S_P_I
TTAGCTATTGAGCTTTCAATAGCTGTCGAATAATAATAGCGAAGAAAGTTGTTATTTACGA
F_S_Y_*

```

```

TACTGTTATTCGCGAGTTGTTACAGCAGCTAGGCCGACAAAGAGCTATATCGAATGCACAAGTTA
M_H_K_F_
GTCTCTCCGACAGACTAAAGAAGTGGCAATTGG
S_L_F_R_Q_T_K_W_Q_L_G_*

```

Para el cluster de sORFs 2L_4, el programa Augustus Gene Prediction predijo para el gen 1, transcripto 1.1, una estructura de 2 exones, de los cuales uno contiene 844 pares de bases y el otro 1682 pares de bases, y un intrón de 69 pares de bases. Para el gen 1, transcripto 1.2, predijo una estructura de 2 exones, uno de 844 pares de bases, y el otro de 583 pares de bases, y un intrón de 69 pares de bases. Para el gen 2.1 predijo una estructura de 2 exones, uno de 1508 pares de bases y, el otro de 241 pares de bases, y un intrón de 127 pares de bases. La estructura indica una secuencia repetitiva de

Se encontró acuerdo con espectro de masas para el péptido KWQLAGQTAEK con una probabilidad de $p=0.068$ y un valor $E=0.000285737204312655$, y para el péptido HLMHLFTALVTVFLPPKGQYWDR con una probabilidad de $p=0.06$ y un valor $E=0.000305832558931141$.

Evidencia de EST:

gi|133838108|gb|EL871737.1|:

```

TGCATTGCCTTAGCTGATGACCTGCCTTAGGCAATTAGGCAAAGTGTAGTCTTGTAGTCATGCAA
CCAAGAGAATTGGGTGGTAGCAGCTAGCGTCAACGATTCTGCCACCTGAACGCCCTGGCGCATAGG
TTGCCATGGCGCAATCCCCGGCCTCCAAAGTCTACATCGCTGCCAGGAATGCGCAACGATTCCC
CGACGGAATAAGGGCAAAAGACCGGATCTCCAAGCGCTCCACTTAGCTGGCTCGACGCATCC
AGCTTTGCAGCAGCACTTGCACTATGATGCAAGCCAGCGATTGCTCAGTGGGCCAAACCTTCAATG
CACGAATGTGATCGTTAAACTTGTCCGACAATTCCGAAGCGATGCCACTGAACCATTCCGTACTACCT
TAAACCCAGAATCTCGTTATGTGCGCTGAAAAACGAGACGCCATTATCAAACCTTTGAAGCAACT
CTAAAGCCGCTTCGTAATTGCTGTTGAAATCTCAAATGATCGGATAGTTCCAGCGCTGAATTCTCAA
ACATGACCTCAGATGTTGAAATGTCTCAATGTTGGAGAGGTCCGGATGGCTGTCGATTATGCTCGTGAAC
ACGGATTAAAATCCGCCAGTTGCGTAGCCTCCGCCAACGTTGGCAGCTGCACAGCGGCAACGGCA
TCGGCCTCGGCCGCGCTGCTTGGAGGTCCACTACACTGGTGGGGCACAACACCTCCGCAAGCGTTGA
GTGCGACCGAATGCACATTGCGTTGGCTATTCCGAGCCACACTAGCCTGAATTCAACGATGAAT
TCATCGAAACTATCGCTCATCTCACTGCCAATTGCGAAATCCAATTTC

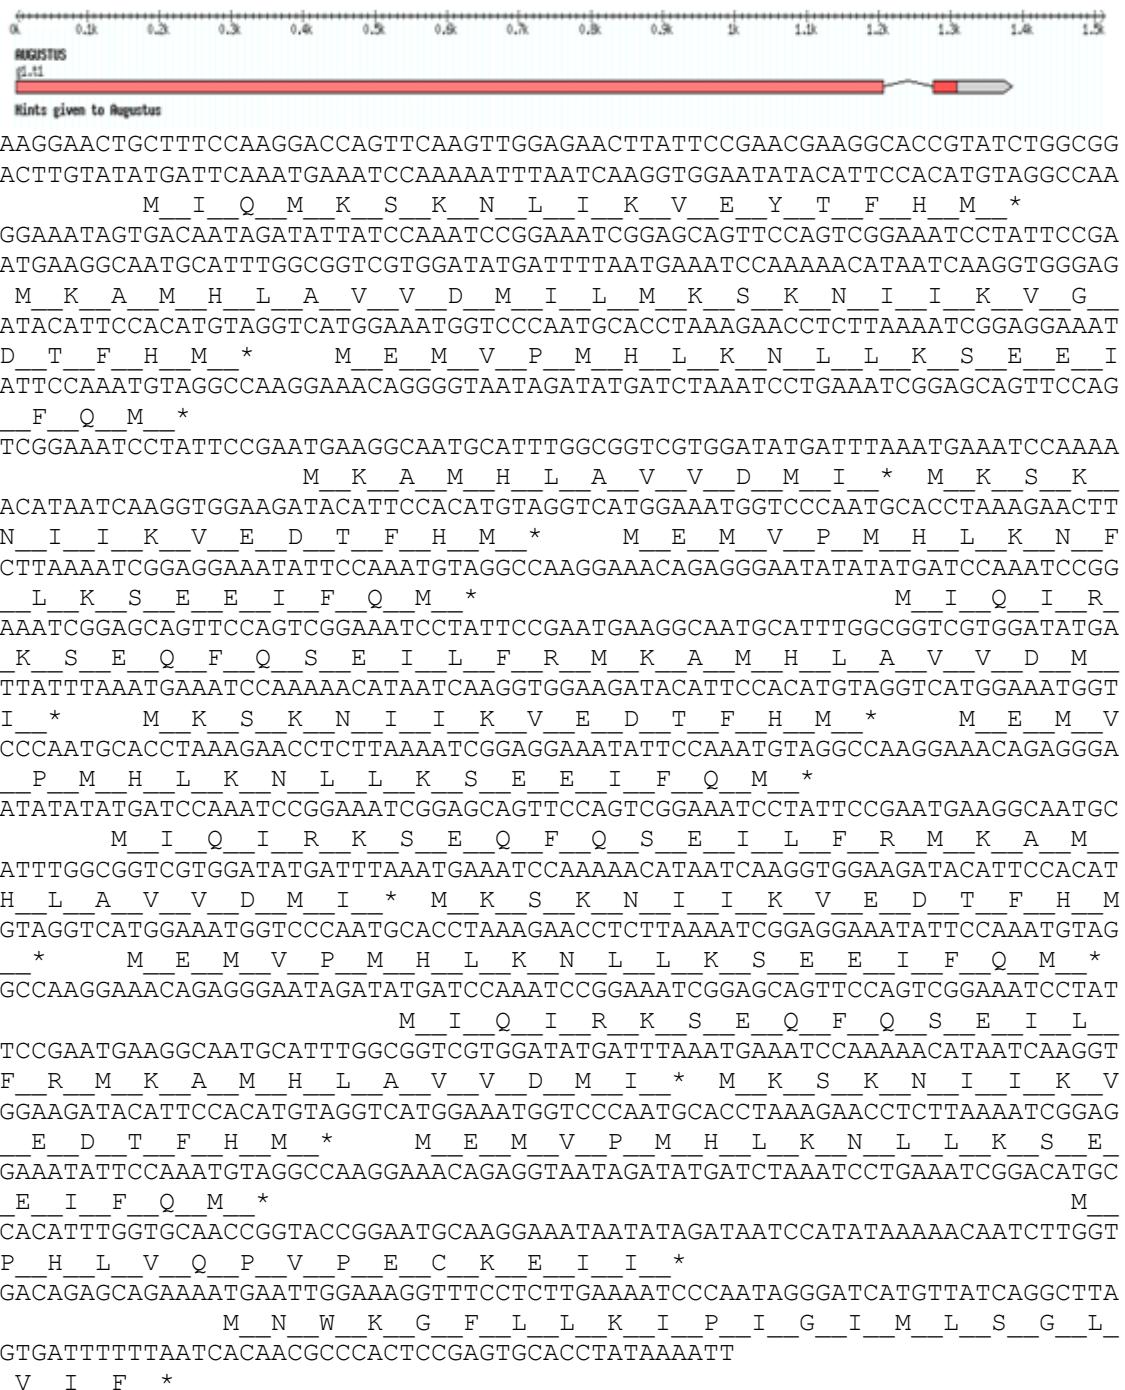
```

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 26 sORFs. El sORF 18 es una duplicación desplazada del sORF 1. La transcripción se basa en la presencia de un EST en la base de datos pública y la probable traducción en la presencia en bases de datos de un péptido definido por espectrometría de masas que cumpliría con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación. Esto significa que al menos uno de los sORFs codificados por este transcripto es traducido. En el caso del primer péptido, corresponde al marco de lectura

AAGTGGCAATTGGCGGGACAGACAGCCGAAAAA, donde dicho péptido se encuentra entre dos sitios de dos aminoácidos básicos, que es el sitio de corte de la tripsina usada para la digestión de muestras proteicas por espectrometría de masas.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_67



Para la región genómica 2L_67, el programa Augustus Gene Prediction predijo una estructura compuesta por 2 exones, uno de 1205 pares de bases, y el otro de 108 pares de bases, y un intrón de 60 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido PHLVQPVPECKEII con una probabilidad de $p=0.037$ y un valor $E=4.1569837010652e-05$.

Evidencia de ESTs:

gi|103649946|gb|EC051174.1|;

```
ATGCACCAAATGTGGCATGTCGATTAGGATTTAGATCATATCTATTACCTCTGTTCTGGCCTAC  
ATTGGAATATTCCTCCGATTTAAGAGGTTCTTAGGTGCATTGGACCATTCCATGACCTACATGT  
GGAATGTATCTTCCACCTTGATTATGTTGGATTCATTAAATCATATCCACGACCGCCAATGCAT  
TGCCTCATTGGAATAGGATTCCGACTGGAACTGCTCCGATTCCGGATTGGATCATATCTATTCCC  
TCTGTTCTGGCCTACATTGGAATATTCCCTCGATTAAAGAGGTTCTTAGGTGCATTGGACCA  
TTTCCATGACCTACATGTGGATGTATCTTCCACCTGATTATGTTGGATTCATTAAATCATATC  
CACGACCGCCAATGCATTGCCCTCATTGGAATAGGATTCCGACTGGAACTGCTCCGATTCCGGATT  
TGGATCATATATTCCTCTGTTCTGGCTACATTGGAAT
```

gi|103660570|gb|EC054701.1|;

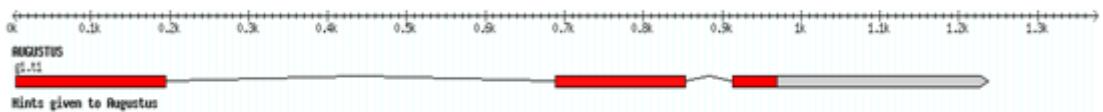
```
AGCCGGCGAGAACCTGGCAAGGATACGTGCAAAGGCGATGGAGGTGCCCACTTGCCTGCCACTGCAA  
AGCGATCCTAACCGGTACGAACCTGGGAATCGTAAACTTGGATTGGATGTGGAGGGCCACTTCCTG  
CTGCCTACACTGATGTTCCCAAATCGAAGCTGGATTGATAATTGTATCCAAGCGGAAGCAGTCCACTA  
TTCTCCTCAGTTGGGAAATGTAGGCCAATCACCTGCTCCACTCGATCGTATATACCAAATAGGCCTA  
GAAACTCAAAATGAAGTCCACAGCCCGTTCAAGGATCTCTCCATAATGTCGTATATCAAACGGTGGTG  
TTGGATATATTCGAGGTATGGCCAAGGAAGTGTCTTCCAAGGACCAGTTCAAGTGGAGAACTTATTCC  
GAACGAAGGCACCGTATCTGGCGGACTTGTATATGATTCAAATGAAATCCAAAATTAATCAAGGTGGA  
ATATACATTCCACATGTAGG
```

gi|103649961|gb|EC051179.1

```
AGCCGGCGAGAACCTGGCAAGGATACGTGCAAAGGCGATGGAGGTGCCCACTTGCCTGCCACTGCAA  
AGCGATCCTAACCGGTACGAACCTGGGAATCGTAAACTTGGATTGGATGTGGAGGGCCACTTCCTG  
CTGCCTACACTGATGTTCCCAAATCGAAGCTGGATTGATAATTGTATCCAAGCGGAAGCAGTCCACTA  
TTCTCCTCAGTTGGGAAATGTAGGCCAATCACCTGCTCCACTCGATCGTATATACCAAATAGGCCTA  
GAAACTCAAAATGAAGTCCACAGCCCGTTCAAGGATCTCTCCATAATGTCGTATATCAAACGGTGGTG  
TTGGATATATTCGAGGTATGGCCAAGGAAGTGTCTTCCAAGGACCAGTTCAAGTGGAGAACTTATTCC  
GAACGAAGGCACCGTATCTGGCGGACTTGTATATGATTCAAATGAAATCCAAAATTAATCAAAGTGGA  
ATATACATTCCACATGTAGG
```

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 17 sORFs. El sexto y el noveno sORF son repeticiones desplazadas del tercero; el séptimo, octavo y noveno sORF se repiten en tándem dos veces más. La transcripción se basa en la presencia de tres ESTs en la base de datos pública, y la probable traducción en la presencia en bases de datos de un péptido definido por espectrometría de masas que cumpliría con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación. Esto significa que al menos uno de los sORFs codificados por este transcripto es traducido. La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_69



```

CTCCATGGAGATCAAGCACCTGATGGACACCTGGTGCCGTACGAGAGAGAAGGTAACGTGGCCCGGC
M_D_T_W_C_P_S_R_E_R_R_*
GCTAGAACATCGCAAGAAGGGCGAGGGCATGCCAACCTTGAGAACACAACACTCACCAGGAAACCTGTACA
TCACCTTCGATGTGGAGTCCCCAAGAAGGATCTTACGGAGGAGGACAAGGAAGGTTAGCATATAACATTA
TCACAAGAGTAATTGTTCATTAATAAACGTTCTAATTCTAGCGCTCAAGAAAATACTCGACCAATCCT
CCATCAATCGCATATAACAATGGACTGTGAATACCCATGTTCATCCCCAATAAAAGTGTGCTGCCGGCTGT
M_D_C_E_Y_P_C_F_I_P_N_K_S_A_R_R_L_
ACTCTAGTTTTAAATGCCTAACTAACAGGGCGACTTGATTGGAACGCCCTAATTCAAGAGATGAC
Y_S_S_F_* M_T
TTTGTCAAAAAGTTGTGCGAAAACAATTAAATTAGTTAGAATTGTAAAGAGATGCAAAGGTGTAA
L_F_K_V_R_K_Q_F_N_F_S_L_E_F_C_K_I_A_K_V_*
TGAGAGGAAACTATTAAGGCGGTTCTGCCGACAAAAGGAATTGCAACAAAACCAACCCACAAAAA
TAAAGCGGATTAAATTATACAACTTGCAGAGCTACTATTTGATTACTGTTTAAAGGGAT
TTTTGATTGTCTCAGAAATAATTAAATTGAAAATTTAGATAGCAGACATGGCTGATTATT
GCAACCTGGCTCAGCTGCGATAACTGGCGCAGGAATCGCAAGAAGGGCAGGGCATGCCAACTTG
M_P_N_F_
AGAACACAAACCTCACCGAACCTGTACATCACCTCGATGTGGAGTCCCCAAGAAGGATCTACGGA
E_N_N_N_L_T_G_N_L_Y_I_T_F_D_V_E_F_P_K_K_D_L_T_E
GGAGGACAAGGAAGGTTAGCATATACATTACAGAGTAATTGTTCATTAATAACGTTCTAATT
E_D_K_E_G_*
TAGCGCTCAAGAAAATCTCGACCAATCCTCCATCAATCGCATATAACAATGGACTGTGAATACCCATGTT
M_D_C_E_Y_P_C_
TCATCCCCAATAAAAGTGTGCGCCGGCTGTACTCTAGTTTAAATGCCTAACTAACAGGGCGACTTGA
F_I_P_N_K_S_A_R_R_L_Y_S_S_F_*
TTTGGAACGCCCTAATTCAAGAGATGACTTGTCAAAAAGTTGTGCGAAAACAATTAAATTAGT
M_T_L_F_K_K_V_V_R_K_Q_F_N_F_S_
TTAGAATTGTAAAATAGCAAAAGTGTAAATGAGAGGAACTATTAAGGCGGTTCTGCCGACAAAAGG
L_E_F_C_K_I_A_K_V_*
AATTGCAACAAAACCAACCCCCACAAAATAAGCGGATTAAATTATACAACTTGCAGAGCTACT
ATTTTGATTACTGTTTAAAGGGATTTTGATTGTCTCAGAAATAATTAAATTGAAAATCTA
TATTAAGACAATCGATAGGCTGCATTATTGCAACCTGGCTCAGCT

```

Para la región genómica 2L_69, el programa Augustus Gene Prediction predijo una estructura compuesta por 3 exones, uno de 189 pares de bases, el segundo de 164 pares de bases, y el tercero de 323 pares de bases, y 2 intrones, uno de 495 pares de bases y el segundo de 60 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido DLTEEDKEG con una probabilidad de $p=0.068$ y un valor $E=0.00078340696005875$.

Evidencia de ESTs:

```

gi|114070047|dbj|BP553224.1|;
TTTTTTTTTTTTTTTTTTTTGTATATAATTAAATCCGTTTATTTGTGGGGTTGGTTTT
GTTGCAATTCTTTGTCGGCAGGAACCGCCTTAATAGTCCCTCTCATTACACTTTGCTATTAA
AAATTAAACTAAATTAAATTGTTTCGCACAACCTTTGAACAAAGTCATCTCTGAATTAGGGC
GTTCCCAAATCAAAGTCGCCGTTAGTTAGGCATTAAAACACTAGAGTACAGCCGGGAGCACTTTAT
TGGGGATGAAACATGGGTATTACAGTCCATTGTATATGCGATTGATGGAGGGTTGGTCAGTATTTCT
TGAGCGCTCCTGTCCTCCGTAAAGATCCTTGTGGGAACCTCCACATCGAAGGTGATGTACAGGTT
GCCGGTGAGGTTGTTCTCAAAGTTGGCATGCCCTGCCCTTGTGGGATTCTAGCGCCGGGCCAC
GTTACCTCTCTCGTACAGGGCACCAGGTGTCCATCAAGGTGTTGATCTCATGGAGAAGCCGACAA
GGGCATCCTGCAGACTGATGGTCACGTTCGTACAGATCATCATTCTGCGAAGAATCGGGATGCGG

```

CATTTGTTGAACCCGACAATGAAGTCGCCGGCCCCCATCGATATGTGGCTCCCC

gi|8120729|gb|AW943021.1|;

ATAATTTAAATCCGCTTATTGTGGGGTTGGTTTGTTGCAATTCTTTGTCGGCAGGAACCGCCTTAATA
CTTAATAGTCCCTCTCATTACACTTTGCTATTACAAAATTCTAAACTAAAATTAAATTGTTTCGC
ACAACCTTTGAACAAAGTCATCTTGAATTAGGGCGTCCCAAATCAAAGTCGCCCTGTTAGTTAG
GCATTTAAAAACTAGAGTACAGCCGGCAGCACTTTATTGGGGATGAAACATGGGTATTACAGTCCAT
TGTATATGCGATTGAGGATTGGTCGAGTATTCTTGAGCGCTTGTCCCTCCGTAAGATC
CTTCTGGGAACCTCACATCGAAGGTGATGTACAGGTTGCCGG
ATGCCCTGCCCTCTTGCAGGATTCTAGGCCGGCACGTTACCTCTCGTACGGGACCAAGGT
GTCCATCAAGGTGCTGATCTCATGGAGAACGGACAGGGCATCCTGCAGACTGATGGTCACGTTCGT
GT

gi|103772525|gb|EC090092.1|;

ATGACCGCTTATTGTGGGGTTGGTTTGTTGCAATTCTTTGTCGGCAGGAACCGCCTTAATA
GTTCCCTCTCATTACACTTTGCTATTACAAAATTCTAAACTAAAATTAAATTGTTTCGCACA
CTT
TTTGAAACAAAGTCATCTTGAATTAGGGCGTCCCAAATCAAAGTCGCCCTGTTAGTTAGGCATT
AAA
ACTAGAGTACAGCCGGCAGCACTTTATTGGGGATGAAACATGGGTATTACAGTCCATTGTATAT
GCGATTGATGGAGGATTGGTCGAGTATTCTTGAGCGCTTGTACAGGTTGCCGGTAGGGTGTACT
GGGAACCTCACATCGAAGGTGATGTACAGGTTGCCGGTAGGGTGTACTCAAAGTTGGGCATGC

gi|49379138|gb|CO320704.1|;

ATGACCGCTTATTGTGGGGTTGGTTTGTTGCAATTCTTTGTCGGCAGGAACCGCCTTAATA
GTTCCCTCTCATTACACTTTGCTATTACAAAATTCTAAACTAAAATTAAATTGTTTCGCACA
CTT
TTTGAAACAAAGTCATCTTGAATTAGGGCGTCCCAAATCAAAGTCGCCCTGTTAGTTAGGCATT
AAA
ACTAGAGTACAGCCGGCAGCACTTTATTGGGGATGAAACATGGGTATTACAGTCCATTGTATAT
GCGATTGATGGAGGATTGGTCGAGTATTCTTGAGCGCTTGTACAGGTTGCCGGTAGGGTGTACT
GGGAACCTCACATCGAAGGTGATGTACAGGTTGCCGGTAGGGTGTACTCAAAGTTGGGCATGC

gi|107222932|gb|EC203778.1|;

GCTTATTGTGGGGTTGGTTTGTTGCAATTCTTTGTCGGCAGGAACCGCCTTAATAGTTCCC
TCTCATTACACTTTGCTATTACAAAATTCTAAACTAAAATTAAATTGTTTCGCACA
CTT
TTTGAAACAAAGTCATCTTGAATTAGGGCGTCCCAAATCAAAGTCGCCCTGTTAGTTAGGCATT
AAA
ACTAGAGTACAGCCGGCAGCACTTTATTGGGGATGAAACATGGGTATTACAGTCCATTGTATATGCGATT
GATGGAGGATTGGTCGAGTATTCTTGAGCGCTTGTACAGGTTGCCGGTAGGGTGTACTCAAAGTTGGGCAT
TCCACATCGAAGGTGATGTACAGGTTGCCGGTAGGGTGTACTCAAAGTTGGGCATGCTCTGCCCT
TCTTGCGGATTCTAGGCCGGCACGTTACAGGTTGCCGGTAGGGTGTACTCAAAGTTGGGCAT

gi|49230633|gb|CO308755.1|;

GCTTATTGTGGGGTTGGTTTGTTGCAATTCTTTGTCGGCAGGAACCGCCTTAATAGTTCCC
TCTCATTACACTTTGCTATTACAAAATTCTAAACTAAAATTAAATTGTTTCGCACA
CTT
TTTGAAACAAAGTCATCTTGAATTAGGGCGTCCCAAATCAAAGTCGCCCTGTTAGTTAGGCATT
AAA
ACTAGAGTACAGCCGGCAGCACTTTATTGGGGATGAAACATGGGTATTACAGTCCATTGTATATGCGATT
GATGGAGGATTGGTCGAGTATTCTTGAGCGCTTGTACAGGTTGCCGGTAGGGTGTACTCAAAGTTGGGCAT
TCCACATCGAAGGTGATGTACAGGTTGCCGGTAGGGTGTACTCAAAGTTGGGCATGCTCTGCCCT
TCTTGCGGATTCTAGGCCGGCACGTTACAGGTTGCCGGTAGGGTGTACTCAAAGTTGGGCAT

gi|103773345|gb|EC090523.1|;

ATGACCGCTTATTGTGGGGTTGGTTTGTTGCAATTCTTTGTCGGCAGGAACCGCCTTAATA
GTTCCCTCTCATTACACTTTGCTATTACAAAATTCTAAACTAAAATTAAATTGTTTCGCACA
CTT
TTTGAAACAAAGTCATCTTGAATTAGGGCGTCCCAAATCAAAGTCGCCCTGTTAGTTAGGCATT
AAA
ACTAGAGTACAGCCGGCAGCACTTTATTGGGGATGAAACATGGGTATTACAGTCCATTGTAT
ATGCGATTGATGGAGGATTGGTCGAGTATTCTTGAGCGCTTC

gi|148890392|gb|ES690303.1|;

AGTCGTCGACCGCTTATTAGTGGGGTAGGTTGTTGCAATTCTTTGTCGGCAGGAACCGCCTTAATA
AATAGTCCCTCTCATTACACTTTGCTATTACAAAATTCTAAACTAAAATTAAATTGTTTCGCACA
ACTT
TTTGAAACAAAGTCATCTTGAATTAGGGCGTCCCAAATCAAAGTCGCCCTGTTAGTTAGGCATT
TT
AAA
ACTAGAGTACAGCCGGCAGCACTTTATTGGGGATGAAACATGGGTATTACAGTCCATTGTAT
ATATGCGATTGATGGAGGATTGGTCGAGTATTCTTGAGCGCTTGTACAGGTTGCCGGTAGGGTGTACTCAAAGTTGGGCAT

CTTGGGAACTCCACATCGAAGGTGATGTACAGGTTGCCGGTGAGGTTGTTCTCAAAGTTGGCATG
CCCTCGCCCTTCTTGCAGATTCTAGCGCCGGGCCACGTTACCTTCTCTCGTGCACGGGCACCAGGTGTC
CATCAAGGTGCTTGATCTCCATGGAGAACGGCACAAGGGCATTGCAGACTGATGGTCACGTTCGTGA
CAGATCATCATTCTGCGCAGGAATCGCGATGCCGATTTGTAACCCGACAATGAGGTCGCCGGC
TCCCCATCGATATGGCTCCCCCTC

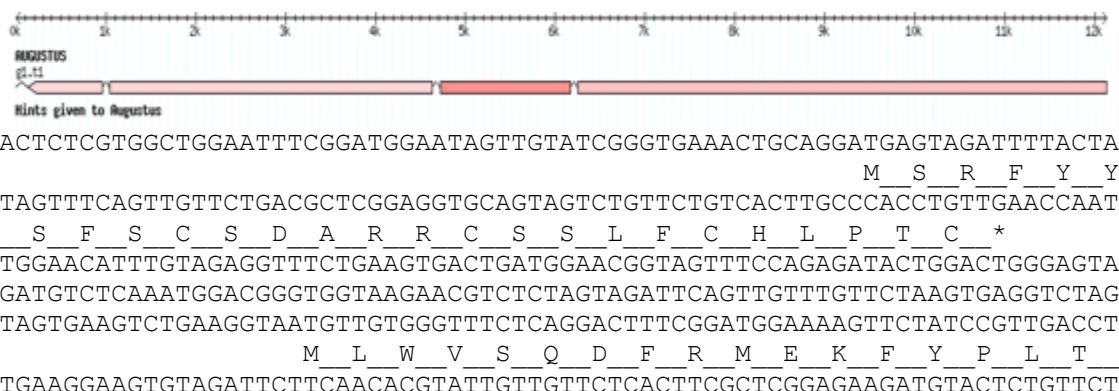
gi|148890367|gb|ES690278.1|;
CGTCGTCGACGCTTATTGTGGGGTGGTATAGTTGCAATTCTTTGTCGGCAGGAACCGCCTAA
TAGTTCCCTCTCATTACACTTTGCTATTACAAAATTCTAAACTAAAATTAAATTGTTTCGCACAAC
TTTTTGAAACAAAGTCATCTCTGAATTAGGGCGTCCCAAATCAAAGTCGCCCTGTTAGTTAGGCATT
AAAAAAACTAGAGTACAGCCGGCAGCACTTATATTGGGGATGAAACATGGGTATTACAGTCATTGTAT
ATGCGATTGATGGAGGATTGGTCGAGTATTCTTGAGCGCTTCCTGTCCTCCGTAAGATCCTTCT
TGGGAACTCCACATCGAAGGTGATGTACAGGTTGCCGGTGAGGTTGTTCTCAAAGTTGGCATGCC
CTCGCCCTTCTTGCGGATACTAGCGCCGGCCACGTTACCTTCTCTCGTGCACGGGCACCAGGTGTC
TCACGGTGCCTGATCTCCATGGAGAACGGCACAATGGCATTGCAAGACTGATGGTCACGTTCGTGTACC
GATCACCAATTCTGCGCAGGAATCGCAGATTGGCATTGTAACCCGCAAATGAGGTCGCGA

gi|1704395|gb|AA140799
ATAATNTAAATCCGCTTATTGTGGGGTTGGTTTGTGCAATTCTTTGTTGGCAGGAACCGC
CTTAATANTCCCTCTCATTACACTTTGCTATTACAAAATTCTAAACTAAAATTAAATTGTTTCGC
ACAACCTTTTGAAACAAAGTCATCTCTGAATTAGGGCGTCCCAAATCAAAGTCCCCCTGTTAGTTAG
GCNTTAAAAACTATAGTACAGCCGGCAACACTTTATTGGGGATGAAACATGGGTATTNCAGTC
TGTCTATGCGATTGATGGAGGATTGGTCNAATTNTTCTTGAACGCNTCCNTGTCCTCCCTCCG
CCNTCTTGGGAACTCCNCATCCAA

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 6 sORFs. El quinto y sexto sORF son repeticiones del segundo y tercero sORF. La transcripción se basa en la presencia de diez ESTs en la base de datos pública, lo que indicaría un alto nivel de expresión y la probable traducción en la presencia en bases de datos de un péptido definido por espectrometría de masas que cumpliría con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación. Esto significa que al menos uno de los sORFs codificados por este transcripto es traducido.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_70



L_K_E_V_* M_Y_S_V_L
 GTCAATTGCCAACCTGTTGAACCAATTGGAACATTGTAGTGGTTCAGAAGTGACTGATGGAACAGTTG
 _S_I_A_H_L_L_N_Q_L_E_H_L_* M_E_Q_L
 TTTCCAGAGATGCTGGACTGGGAGTAGATGCCTCAAATGCCGGGTGGTGGAACGTCTAGTAGATT
 F_P_E_M_L_D_W_E_* M_P_Q_M_A_G_W_L_E_R_L_*
 AGTCGTTGTTCTGAGTGAGGTCTAGTTGTGAAGGTAATGTTGTTGGTGTCTCAGGACTTC
 M_L_L_V_S_Q_D_F_R
 GATGGAGTAGTTCTATCCGCTGACCTTGAAGGAAGTGTAGATTCTCAACCGTATTGTAGTTGACTT
 M_E_*
 CGCTCGGGTGCAGTTGTCTGCCACTTGCCCACCTGTTGAACCAATTGGAACATTGTGGTGGT
 TTCTGAAGTTACTGGTGGAACAGCAGTATCTAGAGTTACTGGCTGGGAGTAGATGCCTCAAATGGCTGG
 M_P_Q_M_A_G
 GTGGTTGGAACGTCTAGTAGATTCACTGTTGATCTGAGTGAGGTCTTGTGAAAGTCTGAAGGTA
 W_L_E_R_L_*
 ATGTTGTGGGTGTCTCAGGACTTCCGGATGGAGAAGTTCTATCCGCTGACCTAGGAGGAAGTGTAGATT
 M_L_W_V_S_Q_D_F_R_M_E_K_F_Y_P_L_T_*
 TTCAACACGTATTGTAGTTCTGACTTCGCTCGGCGGTGCAGTTGTCTGCCACTTGCCCACCACAC
 CTGTTGAACCAATTGGAACATTGTGGTGGTTCTGAAGTTACTGATGGAACAGCAGTTCTAGAGTTAC
 M_E_Q_Q_F_L_E_L
 TGGTCTGGGAGTAGATGCCCTAAATGCCGGGTGGTGGAACGTCTAGTAGATTCACTGTTGATCT
 L_V_W_E_* M_P_Q_M_A_G_W_L_E_R_L_*
 GAGTGAGGTCTAGTAGTGAAGGTAATGTTGTTGGTGTCTCAGGACTTCCGGATGGAGTAGTT
 M_L_W_V_S_Q_D_F_R_M_E_*
 TATCCGTTGACCTTGAAGGAAGTGTAGATTCTCAACACCTATTGTAGTTCTGACTTCGCTCGGCGTTGC
 AGTAGTCTGCTCTGTCACTTGCCCACCTGTTGAACCGATTGGAACATTGTAGTGGTTCTAAAGTAAC
 GATGGAACAGTTGTTCCAGAGATGCTGGACTGGGAGTAGATGCCCTAAATGCCGGGTGGTGGAACGT
 M_E_Q_L_F_P_E_M_L_D_W_E_* M_P_Q_M_A_G_W_L_E_R_
 CTCTAGTAGATTCACTGTTGATCTGAGTGAGGTCTAGTTGTGAAGGTAATGTTGTTGGTGT
 L_* M_L_W_V
 CTCAGGACTTCGGATGGAGTAGTTCTATCGTTGACCTGAAGGAAGTGTAGATTCTCAACACCTATT
 S_Q_D_F_R_M_E_*
 GTAGTTCTGACTTCGCTCGGCGTTGCAGTAGTCTGCTCTGCACTGCCACCTGTTGAACCGATTGGAA
 CATTTGTAGTGGTTCTGAAGTTACTGGGGAAACAGCAATTCTAGAGTTACTGGTCTGGGAGTAGATGA
 M
 CTCAAATGGCTGGGTGGTGGAACGTCTCTAGAAGATTCACTGTTGATCTGAGTGAGGTCTAGTTGTG
 T_Q_M_A_G_W_L_E_R_L_*
 AAGTCTGAAGGTAATGTTGTTGGTGTCTCAGGACTTCCGGATGGAGGAGTTCTATCGTTGACCTCGAAG
 M_L_W_V_S_Q_D_F_R_M_E_*
 GAAGTGTAGATTCTCAACCGTATTGTAGTTCTGACTTCGCTCGGCGGTGCAGTAGTCTGCTCTGTCAC
 TTGCCACCTGTTGAACCACTTGTAAGTGGTTCTAAAGTAACTAGATGGAACAGTTGTTCC
 M_E_Q_L_F_P
 AGAGATGCTGGACTGGGAGTAGATGCCCTAAATGCCGGGTGGTGGAACGTCTAGTAGATTCACTG
 E_M_L_D_W_E_* M_P_Q_M_A_G_W_L_E_R_L_*
 TTTGATCTGAGTGAGGTCTAGTTGTGAAGGTAATGTTGTTGGTGTCTCAGGACTTCCGGATGG
 M_L_L_V_F_Q_D_F_R_M
 AGTAGTTCTATCCGTTGACCTGAAAGGAAGTGTAGATTCTCAACACGTATTGTAGTTCTGACTTC
 E_*
 GGAGAAGATGTAGTTGTTCTGCACTTGCCCACCTGTTGAACCGATTGGAACATTGTAGTGGCTCTG
 AAGTGACTGATGGAACAGTTGTTTCAGAGATGCTGGACTGGGAGTAGATGCTCAAATGGACGGGTGGT
 M_E_Q_L_F_P_E_M_L_D_W_E_* M_S_R_M_V_G_W
 TGGAACGTCTAGTAGATTCACTGTTGTTCTGAGTGAGGTCTAGTTGTGAAGGTAATGTT
 M_L_L_E_R_L_* M_L
 GTTGGTGGTTCAAGGACTTCCGGATGGAGTAGTTCTGACCTGTTGAAGGAAGTGTAGATTCTCA
 L_V_F_Q_D_F_R_M_E_*
 ACACGTATTGTAGTTCTGACTTCGCTCGGAGAAGATGTAGTTGTTCTGCACTGCCACCTGTTGAAC
 CGATTGGAACATTGTAGTGGCTCTGAAGTGACTGATGGAACAGTTGTTTCAGAGATGCTGGACTGG
 M_E_Q_L_F_S_E_M_L_D_W
 AGTAGATGCCTCAAATGGACGGGTGGTGGAACGTCTAGTAGATTCACTGTTGTTCTGAGTGAGG
 E_* M_P_Q_M_D_G_W_L_E_R_L_*
 CTAGTTATGAAGTCTGAAGGTAATGTTGTTGGTGTCTCAGGACTTCCGGATGGAGAAGTTCTATCG
 M_L_W_V_S_Q_D_F_R_M_E_K_F_Y_P_L_

ACCTTGAAGGAAGTAGATTCTCAACACGTATTGAGTTCTGACTTCGCTCGGCGGTGCAGTAGTCTG
 T_L_K_E_V_*
 TCCTGTCACCTGCCACCTGTTGAACCCATTGAAACACTTGTAGTGTTCTAAAGTAACGTGATGGAACA
 M_E_Q
 GTTGTTCAGAGATGCTGGACTGGGAGTAGATGTCCTGAATGGTCGGGTGGTGGAACGTCTAGTAG
 L_F_P_E_M_L_D_W_E_* M_S_R_M_V_G_W_L_E_R_L_*
 ATTCAAGTTGTTCTGAGTGAGGTCTAGTTGTGAAGTCTGAAGGTAATGTTGTTGGTGTTCAGGACT
 M_L_L_V_F_Q_D
 TTCGGATGGAGTAGTTCTATCCGTTGACCTGAAAGGAAGTAGTGAGATTCTCAACACGTATTGAGTTCTG
 F_R_M_E_*
 ACTTCGCTCGGAGAAGATGTTGAGTTCTGTCACCTGCCACCTGTTGAACCGATTGGAACACATTGAG
 TGGCTCTGAAGTGACTGATGGAACAGTTGTTCAGAGATGCTGGACTGGAGTAGATGCTCAAATGG
 M_E_Q_L_F_S_E_M_L_D_W_E_* M_L_Q_M
 ACGGGTGGTTGAAACGTCTAGTAGATTCAAGTCGTTGTTGAGTGAGGTCTAGTTATGAAGTCTGAA
 D_G_W_L_E_R_L_*
 GGTAAATGTTGTTGGGTGTCTCAGGACTTCGGATGGAGAAGTTCTATCCGTTGACCTGAAAGGAAGTGAG
 M_L_W_V_S_Q_D_F_R_M_E_K_F_Y_P_L_T_L_K_E_V_*
 ATTCTCAACACCTATTGAGTTCTGACTTCGCTCGGCGGTGCAGTAGTCTGTCCTGTCACCTGCCACC
 TGTTGAACCAATTGGAACATTGAGTTCTGAAAGTGACTGATGGAACAGTAGTTCCAGAGATGCT
 GGACTGGGAGTAGATGCCTCAAATGGCCTGGTGGTGGAACCGTCTAGTAGATTCAAGTCGTTGTTCTG
 M_P_Q_M_A_W_W_L_E_R_L_*
 AGTGAGGTCTAGTTGAGTGAAAGTAATGTTGGTGTCTCAGGACTTCGGATGGAGTAGTTCTATC
 M_L_V_S_Q_D_F_R_M_E_*
 CGCTGACCTGAAAGGAAGTGAGATTCTCAACCGTATTGAGTTCTCACTTCGCTCGGAGAAGATGTA
 GTTGTTCTGTCACCTGCCACCTGTTGAACCGATTGGAACATTGAGTTGTTCTAAAGTAACGATGATG
 M_G
 GAACAGTTGTTCCAGAGATGCTGGACTGGAGTAGATGTCGAATGGTCGGGTGGTGGAACGTCTCT
 E_Q_L_F_P_E_M_L_D_W_E_* M_S_R_M_V_G_W_L_E_R_L_
 AGTAGATTCAAGTCGTTTCTGAGTGAGGTCTAGTTGTGAAGGTAATGTTGGTGGTGTTC
 * M_L_L_V_F_Q
 GGACTTCGGATGGAGTAGTTCTATCCGTTGACCTGAAAGGAAGTGAGATTCTCAACACGTATTGAG
 __D_F_R_M_E_*
 TTCTGACTTCGCTCGGAGAAGATGTTGAGTTCTGTCACCTGCCACCTGTTGAACCGATTGGAACATT
 TGAGTGCTCTGAAGTGACTGATGGAACAGTTGTTCAGAGATGCTGGACTGGAGTAGATGCTTC
 M_E_Q_L_F_S_E_M_L_D_W_E_* M_L_Q
 AATGGACGGGTGGTGGAACCGTCTAGTAGATTCAAGTCGTTGTTCTGAGTGAGGTCTAGTTATGAAGT
 M_D_G_W_L_E_R_L_*
 CTGAAGGTAATGTTGTTGGTGTCTCAGGACTTCGGATGGAGAAGTTCTATCCGTTGACCTGAAAGGAAG
 M_L_W_V_S_Q_D_F_R_M_E_K_F_Y_P_L_T_L_K_E
 TGTAGATTCTCAACACCTATTGAGTTCTGACTTCGCTCGGCGGTGCAGTAGTCTGTCCTGTCACCTGC
 V_*
 CCACCTGTTGAACCAATTGGAACATTGAGTTCTGAAAGTGACTGATGGAACAGTAGTTCCAGAG
 ATGCTGGACTGGGAGTAGATGCCTCAAATGGCCTGGTGGTGGAACCGTCTAGTAGATTCAAGTCGTTG
 M_P_Q_M_A_W_W_L_E_R_L_*
 TTCTGAGTGAGGTCTAGTTGAGTGAAAGTAATGTTGGTGTCTCAGGACTTCGGATGGAGTAGTT
 M_L_V_S_Q_D_F_R_M_E_*
 CTATCCGCTGACCTGAAAGGAAGTGAGATTCTCAACCGTATTGAGTTCTCACCTCGCTCGGAGAAG
 ATGAGTTGTTCTGTCACCTGCCACCTGTTGAACCGATTGGAACATTGAGTTGTTCTAAAGTAAC
 TGATGGAACAGTTGTTCCAGAGATGCTGGACTGGAGTAGATGTCCTCGAATGGTCGGGTGGTGGAACCG
 M_E_Q_L_F_P_E_M_L_D_W_E_* M_S_R_M_V_G_W_L_E_R
 TCTCTAGTAGATTCAAGTCGTTTCTGAGTGAGGTCTAGTTGTGAAGGTAATGTTGGTGGT
 L_* M_L_L_V
 TTTCAGGACTTCGGATGGAGTAGTTCTATCCGTTGACCTGAAAGGAAGTGAGATTCTCAACACGTA
 F_Q_D_F_R_M_E_*
 TTGTAGTTCTGACTTCGCTCGGAGAAGATGTTGAGTTCTGTCACCTGCCACCTGTTGAACCGATTGG
 AACATTGAGTTGCTGAAAGTGACTGATGGAACAGTTGTTTCAGAGATGCTGGACTGGAGTAGAT
 M_E_Q_L_F_S_E_M_L_D_W_E_* M
 GCCTCAAATGGACGGGTGGTGGAACGTCTCTAGTAGATTCAAGTCGTTGTTCTGAGTGAGGTCTAGTTA
 P_Q_M_D_G_W_L_E_R_L_*
 TGAAGTCTGAAAGGTAATGTTGTTGGTGTCTCAGGACTTCGGATGGAGAAGTTCTATCCGTTGACCTTGA
 M_L_W_V_S_Q_D_F_R_M_E_K_F_Y_P_L_T_L_

AGGAAGTGTAGATTCTTCAACACCTATTGAGTTCTGACTTCGCTCGCGGTGCAGTAGTCTGTCCTGTC
 K_E_V_*
 ACGGCCACCTGTAACCAATTGAAACATTGAGTTCTGACTGATGAAACAGTAGTT
 CCAGAGATGCTGGACTGGAGTAGATGCCTCAAATGCCCTGGTGGTGGAACGTCTAGTAGATTCACT
 M_P_Q_M_A_W_W_L_E_R_L_*
 CGTTGATCTGAGTGAGGTCTAGTTATGAAGTCTGAAGGTAATGTTGGGGTGTCTCAGGACTTCGGAT
 M_L_W_V_S_Q_D_F_R_M
 GGAGAAGTTCTATCCGTTGACCTTGAAGGAAGTGTAGATTCTCAAGACCTATTGAGTTCTGACTTCGC
 E_K_F_Y_P_L_T_L_K_E_V_*
 TCGGAGAAGATGTAGTTGTTCTGTCACCGCCACCTGTTGAACCAATTGAAACATTGAGTTTC
 TGAAGTGAAGTGGAACAGTAGTTCCAGAGATGCTGGACTGGAGTAGATGCCTCAAATGCCGGGTG
 M_P_Q_M_A_G_W
 GTTGGAACGTCTAGTTGATTCACTGAGTGAGGTCTAGTTGTGAAGTCTGAAGGTA
 L_E_R_L_*
 ATGTTGTTGGGTGTCAGGACTTCGGATGGAGAAGTTCTATCCGTTGACCTTGAAGGAAGTGTAGATT
 M_L_W_V_S_Q_D_F_R_M_E_K_F_Y_P_L_T_L_K_E_V_*
 TTCAACACCTATTGAGTTCTGACTTCGCTCGGCGTTGCAGTAGTCTGTCCTGTCACCGCCACCTGTT
 GAACCGATTGGAACATTGAGTTGTTCTAAAGTAACCGATGGAACAGTTGTTCCAGAGATGCTGGAC
 M_E_Q_L_F_P_E_M_L_D
 TGGGAGTAGATGCCTCAAATGGCGGGTGGTGGAACGTCTAGTAGATTCACTGAGTGAGTTCTGAAGGTA
 W_E_* M_P_Q_M_A_G_W_L_E_R_L_*
 AGTCGAGTAGTGGAGTCTGAAGGTAATATTGTTGGGTGTCAGGACTTCGGATGGAGTGGTTCTATCC
 GTTGACCTAGAAGGAAGTGTAGATTCTCAACACGTATTGAGTTCTGACTTCGCTCGGCGGTGAGTAG
 TCTGTCCTGTCACTTGCCCACCTGTTGAACCAATTGAAACATTGAGTTGTTCTGAAAGTGA
 AACAGTAGTTCCAGAGATGCTGGACTGGAGTAGATGCCTCAAATGCCCTGGTGGAACGTCTCTA
 M_P_Q_M_A_W_W_L_E_R_L_*
 GTAGATTCACTGTTGTTCTGAGTGAGGTCTAGTTGTGAAGGTAATGTTGGTGTCTCAGGAC
 M_L_V_S_Q_D
 TTTGGATGGAGTAGTTCTATCCGCTGACCTTGAAGGAAGTGTAGATTCTCAACCGTATTGAGTTCT
 F_R_M_E_*
 GAATTGCTCGGAGAAGATGTAGTTGTTCTGTCACCGCCACCTGTTGAACCGATTGGAACATTGTA
 GTGGTTCTAAAGTAACTGATGGAACAGTTGTTCCAGAGATGCTGAACGGAGTAGATGCCTCAAATG
 M_E_Q_L_F_P_E_M_L_N_W_E_* M_P_Q_M
 GCCTGGTGGTGGAACGTCTAGTAGATTCACTGAGTGAGTTCTGACTTCGCTCGGCGGTGAGTAG
 A_W_W_L_E_R_L_*
 AGGTAATGTTGGTGTCTCAGGACTTCGGATGGAGTAGTTCTATCCGCTGACCTTGAAGGAAGTGTAGAT
 M_L_V_S_Q_D_F_R_M_E_*
 TCTTCAACCGTATTGAGTTCTCACTTCGCTCGGAGAAGATGTAGTTGTTCTGTCACCGCCACCTG
 TTGAACCGATTGGAACATTGAGTTCTAAAGTAACTGATGGAACAGTTGTTCCAGAGATGCTGA
 M_E_Q_L_F_P_E_M_L
 ACTGGGAGTAGATGCCTCAAATGGCGGGTGGTGGAACGTCTG
 N_W_E_* M_P_Q_M_G_G_W_L_E_R_L_*

Para la región genómica 2L_70, el programa Augustus Gene Prediction predijo una estructura compuesta por 4 exones, uno de 832 pares de bases, el segundo de 3596 pares de bases, el tercero de 1443 pares de bases, y el cuarto de 5884 pares de bases, y 3 intrones, uno de 78 pares de bases, el segundo de 86 pares de bases, y el tercero de 86 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido PQMGGWLER1 con una probabilidad de $p=0.065$ y un valor $E=0.000774676309619807$; para el péptido MLQMDGWLER con una probabilidad de $p=0.076$ y un valor $E=0.000109970367566957$; para el péptido LQMDGWLER con una probabilidad de $p=0.099$ y un valor $E=0.000580829931336663$; para el péptido TQMAGWLER con una probabilidad de $p=0.026$ y un valor $E=0.000211884516943163$.

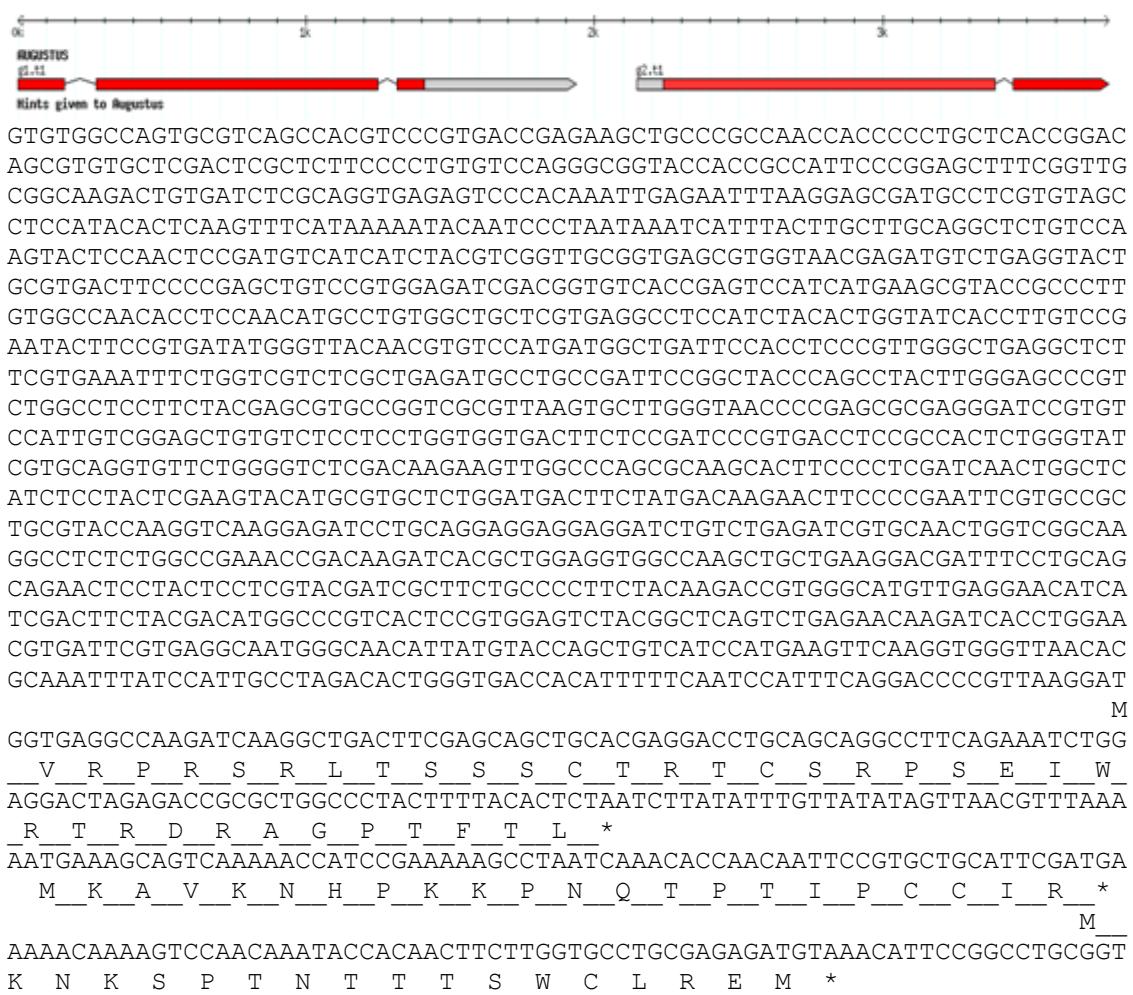
Se halló evidencia de ESTs:

```
gi|15479873|gb|BI588451.1|
GTCTCAGGACTTCGGATGGAGTAGTTCTATCCGCTGACCTTGAAAGGAAGTGTAGATTCTCAACCGCGTA
TTGTAGTTCTCACTCGCTCGGAGAAGATGTAGTTGTTCTGTCACCTGCCAACCTGTTGAACCGATTGG
AACATTGTAGTGGTTCTAAAGTAACGTGATGGAACAGTTGTTCCAGAGATGCTGAACGGAGTAGAT
GCCTCAAATGGGCGGGTGGTGGAACGTCTAGTAGATTCACTGTTGATCTGAGTGAGGTCTAGTTA
TGAAGTCTGAAGGTAATGTTGGGTGTCAGGACTTCGGATGGAGAAGTTCTATCCGTTGACCTTG
AGGAAGTGTAGATTCTCAAGACCTATTGTAGTTCTGACTTCGCTCGGAGAAGATGTAGTTGTTCTGT
```

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 60 sORFs. Se pueden observar varias repeticiones en tandem y varias desplazadas. La transcripción se basa en la presencia de un EST en la base de datos pública y la probable traducción en la presencia en bases de datos de 4 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación. Esto significa que al menos 4 de los sORFs codificados por este transcripto son traducidos.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada

Gen 2L_80



```

TAATACTTCCCCTAACACGCCCTCCGCCCTGAAGGGCAACTCTAGGCAACAGCAACTACAACGT
CCTGCTATGTAATTCCATTACAACAACACAAACATACACTTGAATAAAAGTACACGGACACTGGCG
M__Y__F__H__L__Q__Q__H__Q__H__T__L__E__*
CACACACAACACATACATAAAAGACACAAATACAAATGCATGCATAAATAGTATTATTGTTAATGAATG
M__N__
GAAATTCTTGTATTGTGAAAAAAAGTCATGTTCTCCCTGTTGTTGTTAAATTATGAAATATT
G__N__S__C__L__F__V__K__K__V__M__F__S__P__C__L__F__V__K__F__M__*
TAAAGTATGAAATATTAAATGTACGAATAAAAGTCAACAAACAAATACATTAAATGAAAGTGAAT
TTCACTGGCAGCAGAATGGATATTAAAATGTGTCACCTCGATAAAAGATAATAAGTTAAATATTTT
M__D__I__K__N__V__S__T__R__*
M__C__Q__L__D__K__K__I__I__S__*
TTGAATTAAACCTCATTATATAACATACTTGACTATATGAAAGCTAAGAAATGGGAATATATTGA
M__K__A__K__K__M__G__I__Y__*
AAAGCATAATCTAAATCCTATATCATTCTCAGTCATCACCTAGTCTTCCATAAACTCTGCCCTATT
TATTTTATTATTGACAATATTAGTAAAATTGTACCAAGTGAAGAAATTGTATATATTAAACCAAAT
GGAAAAGAAGTCCTGGGTTGACCGCTTACCTCGTACCAACAGTAACGCAAGTAACGAAGACAGAGCC
CGCAACTCGGGATCGTAAACCAAGATGGGAGCCAAGGGTCCGTGCCTACCCAACGGTTCCGGCTAAGA
M__G__S__Q__G__P__C__L__T__Q__R__F__R__L__R
AGTGCACATGTCCAACCTGCGCTTGCCAACGTAATGACCATAATCCAATCGGTACCCCTCCCCCTCA
S__A__H__V__Q__P__A__L__A__N__V__M__T__I__N__P__I__R__Y__P__L__P__L
ATCACGCAAGCCTGTAGCCGAGCGGAAAGTCCCCATGATAACAGTCAATGACGAGGACAGTTGAAGGAC
N__H__A__S__L__* M__I__Q__S__M__T__R__T__V__*
TTGAGACGTTGACGGACCAATCCCACAAGAGCGCTCACATCGCTTGGAGAAGAATGAGGACTCGGGTT
TTGTGATCGAGCAGGTGGTTGATACGCACAAATATTGTCGGATGAAGAAGAGGAGGAGGCGACGATGGG
TCGCATTTCGGAGTCTCGGTCCGGTGGTCAATGCCGAGGAGATGGCCGGCGCAGCCATGTACGAGCTG
GTTCGCGTGGACACTCCCAGCTTGGTGGAGATCATCGACTGGAGGGTGATATGCCACCATTCAGG
TTTACGAGGATACTCGGGTGTAGCGTGGGTGATCCGTCTACCAGACGGGAAAGCCGCTCTCGTGGA
ATTGGGACCGGCATCATGGCAGCATTCGATGGTATCCAGCGACCATGGGTCCATCAGTGAAC
ACCAACTCCATATACGTGCCAAGGGCATCGATACGCCCTCCCTGCCAGGAACATTGCGTACGAATTCA
CACCGGAAATTGAAGATCGATGCTCTGATCACCGCGGAGACATCTACGGATCTGTTTCGAAAACAG
CATGATGCGACGATACCGCCTGATACTACCGCCCCGACCAAGGGCGATCCGGTGGTTGGCCCGGCC
GGGAACTACTCGTGGACGAGGTGATCGTGGAGACGGAGTTCAACGACGGAGATCACCAAGCACACCATGC
TCCAGGTGTGGCCCGTACGGAGGTGCGTCCGGTGGAGGATAAGCTCCCCAGCAATTCAACACTTTGAC
TGGCCAGCGCCTGGACGCCCTTTCCATGTTGCACTGGGCGGAACCACTGCCATTCCAGGAGCGTT
M__C__P__G__R__N__H__C__H__S__R__S__V__
GGATGTGGAAAGACCGTCATCTCACAGGTGAGAGGGTTCTAAGAGTTAGTTGACAAATGATTACATT
W__M__W__K__D__R__H__L__T__G__E__R__V__S__K__S__L__V__D__K__*
CAATCAACTTATACCCCTAGGCCCTGTCACAAATACTCCAACACTCAGATGTCATCATCTACGTGGCTGC
TGAGCGCGGAAACGAAATGTCGGAGGTTCTCGGACTTCCCGAGCTGAGGTTGAGGTCAATGGCACC
ATGGAATCGATTATGAAGCGGACTGCCCTGGTGGCCAATACCTCAATATGCCGGTGGCTGCCGAGAAG
CCTCGATCTACACGGGCATCACCTCTCGGAATACTCCCGCAGATGGCTACCATGTTGCAATTGAC
GGACTCCACATCTCGATGGCGAGGCCTGCGTGGAGATTCCGGACGTCTGGCCGAGATGCCATTGCG
G

```

Para el cluster de sORFs 2L_80, el programa Augustus Gene Prediction predijo, para el gen1.1, una estructura compuesta por 3 exones de 162 pares de bases el primero, el segundo de 977 pares de bases y el tercero de 619 pares de bases, y 2 intrones, el primero de 109 pares de bases y el segundo de 68 pares de bases; para el gen 2.1 predijo una estructura de 2 exones, el primero de 1241 pares de bases y el segundo de 530 pares de bases, y un intrón de 64 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido SPTNTTSWCLR con una probabilidad de $p=0.017$ y un valor $E=0.000844543161337096$.

Se halló evidencia de ESTs:
gi|13692404|gb|BF500563.2|;

ATTTTATTATTGACAATATTAGTAAAATTGTACCAAGTGAAGAAATTGTATATTTAAACCAAATG

GAAAAGAAGTCCTGGGTTGCACCGCTTACCTCGTTACCAACAGTAACGCAAGTAACGAAGACAGAGGCC
GCAACTCAGGATCGTTAACCAAGATGGGAGCCAAGGTCCGTGCCTCACCAACGGTCCGGCTAACGAA
GTGCACATGTCAAACCTCGCGTGCACGTAATGACCATAATCCAATCCGTAACCGTACCCCTCCCCCTCAA
TCACGCAAGCCTGTAGCCGAGCCGAAAGTCCCCATGATACAGTCATGACGAGGACAGTTGAAGGACT
TGAGACGTTGACGGACCAATCCCACAAGAGCGCTCACATGCCCTGGAGAAGAATGAGGACTCGGGTT
TGTGATCGAGCAGGTGGTGTACGCACAAATATTGTCGGATGAAGAAGAGGAGGAGCGACGATGGGT
CGCATTTCGGAGTCTCCGGTGGTCAATGCCGAGGAGATGGCCGGCGCAGCCATGTACGAGCTGG
TTCGCGTTGGACACTCCCAGCTTGTGGTGTGAGATCATTGACTGGAGGGTGTATGGCCACCATTGAGG
TTACGAGGATACTCGGGTGTGAGCGTGGTGTACCGACGGAAAGCCACTCTCCGTTGAA
TTGGGACCCGGCATGGCAGCATCTTGATGGTATCCAGCACCATTGAGGTCATCAGTGAAC
CCAACCTCCATACGTGCCAAGGGCATCGATACGCCCTCCCTGCCAGGAACAT

gi|13693150|gb|BF506709.2|;

CATTCTCAGTCATCACCTTAGTCTTCCATAAACTTCTGCCCATTTATTTATTTGACAATATTA
GTAAAAATTGTACCAAGTGAAGAAATTGTATATTTAACCAAATGGAAAAGAAGTCCTGGGTTGCACC
GCTTACCTCGTCACCAACAGTAACGCAAGTAACCAAGACAGAGCCGCAACTCGGGATCGTTAACCAA
GATGGGAGCCAAGGTCCGTGCCTCACCAACGGTCCGGCTAACGAGTGCACATGTCAAACCTCGCCTT
GCCAACGTAATGACCATAATCCAATCCGGTACCCCTCCCCCTCAATCACGCAAGCCTGTAGCCGAGCC
GGAAAGCCCCATGATACAGTCATGACGAGGACAGTTGAAGGACTTGAGACGTTGACGGACCAATCC
ACAAGAGCGCTCACATAGCCTGGAGAAGAATGAGGACTCGGGTTTGTGATCGAGCAGGTGGTTGATA
CGCACAAATATTGTCGGATGAAGAAGAGGAGGAGGCGACGATGGGTCGCATTTGGAGTCTCCGGTCC
GGTGGTCAATGCCGAGGAGATGGCCGGCGCAGCCATGTACGAGCTGGTCGCGTGGACACTCCAGCTA
GTTGGTGAGATCATTGACTGGAGGGTGTATGGCCACCATTGAGTTACGAGGATACTCGGGTGTGA
GCGTGGGTGATCCCGTCTACCAGACGGAAAGCCGCTCCGTTGAATTGGGACCCGGCATGGCAG
CATCTCGATGGTATCCAGCACCATTGAGGTCATCAGTGAAC

gi|13698237|gb|BF486355.2|;

AAAAATTGTACCAAGTGAAGAAATTGTATATTTAACCAAATGGAAAAGAAGTCCTGGGTTGCACCGC
TTACCTCGTCACCAACAGTAACGCAAGTAACGAAGACAGAGCCGCAACTCGGGATCGTTAACCAAAGA
TGGGAGCCAAGGTCCGTGCCTCACCAACGGTCCGGCTAACGAGTGCACATGTCAAACCTCGCCTTG
CAACGTAATGACCATAATCCAATCCGGTACCCCTCCCCCTCAATCACGCAAGCCTGTAGCCGAGCCGG
AAAGTCCCCATGATACAGTCATGACGAGGACAGTTGAAGGACTTGAGACGTTGACGGACCAATCCCA
CAAGAGCGCTCACATGCCTGGAGAAGAATGAGGACTCGGGTTTGTGATCGAGCAGGTGGTTGATACG
CACAAATATTGTCGGATGAAGAAGAGGAGGAGGCGACGATGGGTCGCATTTGGAGTCTCCGGTCCGG
GGTCAATGCCGAGGAGATGGCCGGCGCAGCCATGTACGAGCTGGTCGCGTGGACACTCCAGCTTGT
GGTGAGATCATTGACTGGAGGGTGTATGGCCACCATTGAGTTACGAGGATACTCGGGTGTGAGC
GTGGGTGATCCCGTCTACCAGACGGAAAGCCGCTCCGTTGAATTGGGACCCGGCATGGCAGCA
TTTCGATGGTATCCAGCACCATTGAGGTCATCAGTGAACCAACTCCATACGT

gi|13755044|gb|BF489384.2|;

AAAAATTGTACCAAGTGAAGAAATTGTATATTTAACCAAATGGAAAAGAAGTCCTGGGTTGCACCGC
TTACCTCGTCACCAACAGTAACGCAAGTAACGAAGACAGAGCCGCAACTCGGGATCGTTAACCAAAGA
TGGGAGCCAAGGTCCGTGCCTCACCAACGGTCCGGCTAACGAGTGCACATGTCAAACCTCGCCTTG
CAACGTAATGACCATAATCCAATCCGGTACCCCTCCCCCTCAATCACGCAAGCCTGTAGCCGAGCCGG
AAAGTCCCCATGATACAGTCATGACGAGGACAGTTGAAGGACTTGAGACGTTGACGGACCAATCCCA
CAAGAGCGCTCACATGCCTGGAGAAGAATGAGGACTCGGGTTTGTGATCGAGCAGGTGGTTGATACG
CACAAATATTGTCGGATGAAGAAGAGGAGGAGGCGACGATGGGTCGCATTTGGAGTCTCCGGTCCGG
GGTCAATGCCGAGGAGATGGCCGGCGCAGCCATGTACGAGCTGGTCGCGTGGACACTCCAGCTTGT
GGTGAGATCATTGACTGGAGGGTGTATGGCCACCATTGAGTTACGAGGATACTCGGGTGTGAGC
GTGGGTGATCCCGTCTACCAGACGGAAAGCCGCTCCGTTGAATTGGGACCCGGCATGGCAGCA
TTTCGATGGTATCCAGCACCATTGAGGTCATCAGTGAAC

gi|13691260|gb|BF499396.2|;

ATGGGTTACAACGTGTCCATGATGGCTGATTCCACCTCCCGTTGGCTGAGGCTTTCGTGAAATTCTG
GTCGTCTCGCTGAGATGCCTGCCGATTCCGGTACCCAGCCTACTTGGGAGCTCGTCTGGCCTTCTA

CGAGCGTGCCTGGTCGCGTTAAGTGCTTGGTAACCCGAGCGAGGGATCCGTGCCATTGTCGGAGCT
GTGTCTCCTCCTGGTGGTGAACCTCCGATCCCCTGACCTCCGCCACTCTGGTATCGTCAGGTGTTCT
GGGGTCTCGACAAGAAGTGGCCAGCGCAAGCATTCCCCCTGATCAACTGGCTCATCTCCTACTCGAA
GTACATGCGTCTGGATGACTTCTATGACAAGAACCTCCCCGAATTGTCGCCGCTGCGTACCAAGGTC
AAGGAGATCCTGCAGGAGGAGGATCTGTCAGATCGCAACTGGTCGGCAAGGCCTCTGGCCG
AAACCGACAAGATCACGCTGGAGGTGGCCAAGCTGCTGAAGGACGATTCCTGAGCAGAACACTCCTACTC
CTCGTACGATCGCTCTGCCCTCTACAAGACCGTGGCATGTTGAGGAACATCATGACTTCTACGAC
ATGGCCCGTCACTCCGTGGAGTCTACGGCTCAGTCTGAGAACAGATCACCTGGAACGTGATTGTCAGG
CAATGGCAACATTATGTACCAGCTGTCATCCATGAAGTTCAAGGACCCGTTAAGGATGGTGGGCCAA
GATCAAGGCTGA

gi|13688793|gb|BF506216.2|;

AAATTGTACCAAGTGA AAAAATTGTATATTTAAACCAAATGGAAAAGAAGTCCTGGGTTGCACCGCTT
ACCTCGTTCACCAACAGTAACGCAAGTAACGAAGACAGAGCCCGCAACTCGGGATCGTTAAACCAAGATG
GGGAGCCAAGGTCCGTGCCTCACCCAAACGGTTCCGGCTAAGAAGTGCACATGTCAAACCTGCGCTTGCCA
ACGTAATGACCATAATCCAATCCGTACCCCTCCCCCTCAATCACGCAAGCCTGTAGCCGAGCCGGAA
AGTCCCCATGATACTAGTCAATGACGAGGACAGTTGAAGGACTTGAGACGTTGACGGACCAATCCACA
AGAGCGCTCACATCGCCTGGAGAAGAATGAGGACTCGGGTTTGATCGAGCAGGTGGTTGATACGCA
CAAATATTGTCGGATGAAGAAGAGGAGGAGCGACGATGGGTCGATTTCGGAGTCTCGGTCCGGTG
GTCAATGCCGAGGAGATGCCGGCGCAGCCATGTACGAGCTGGTTCGCGTTGGACACTCCAGCTTGTG
GTGAGATCATTGACTGGAGGGTGATATGCCACCATTAGGTTACGAGGATACTCGGGTGTGAGC
GGGTGATCCCGTCTACCAGACGGGAAAGCCGCTCCGTGGAATTGGGACCCGGCATCATGGCAGCATT
TTCGATGGTATCCAGCGACCATTGAGGTCCA

gi|13693563|gb|BF496063.2|;

TTCTGCCCAATTATTTATTGACAATATTAGTAAAAATTGTACCAAGTGA AAAAATTGTATATA
TTTAAACCAAATGGAAAAGAAGTCCTGGGTTGCACCGCTTACCTCGTTCACCAACAGTAACGCAAGTAAC
GAAGACAGAGCCCGCAACTCGGGATCGTTAAACCAAAGATGGGAGCCAAGGTCCGTGCCTCACCCAAACGG
TTCCGGCTAAGAAGTGCACATGTCCAACCTGCGCTTGCCAACGTAATGACCATAATCCAATCCGGTACC
CCCTCCCCCTCAATCACGCAAGCCTGTAGCCGAGCCGGAAAGCCCCCATGATACTAGTCAATGACGAGGAC
AGTTGAAGGACTTGAGACGTTGACGGACCAATCCACAAGAGCGCTCACATAGCCTGGAGAAGAATG
AGGACTCGGGTTTGATCGAGCAGGTGGTTGATACGCAAAATATTGTCGGATGAAGAAGAGGAGGA
GGCAGCATGGTCGCTTTCGGAGTCTCCGGTCCGGTGGCAATGCCGAGGAGATGCCGGCGCAGCC
ATGTACGAGCTGGTTCGCGTGGACACTCCAGCTAGTTGGTGGAGATCATTGACTGGAGGGTGATATGG
CCACCATTAGGTTACGAGGATACTCGGGTGTGAGCGTGGGTGATCCGTCTACCAGACGGGAAAGCC
GCTCTCGTTGAATTGGGACCCGGCATCATGGCAGCATCTCGATGG

gi|13694048|gb|BF496495.2|;

AAAAATTGTACCAAGTGA AAAAATTGTATATTTAAACCAAATGGAAAAGAAGTCCTGGGTTGCACCGC
TTACCTCGTTCACCAACAGTAACGCAAGTAACGAAGACAGAGCCCGCAACTCGGGATCGTTAAACCAAGA
GGGGAGCCAAGGTCCGTGCCTCACCCAAACGGTTCCGGCTAAGAAGTGCACATGTCAAACCTGCGCTTG
CAACGTAATGACCATAATCCAATCCGTACCCCTCCCCCTCAATCACGCAAGCCTGTAGCCGAGCCGG
AAAGCCCCATGATACTAGTCAATGACGAGGACAGTTGAAGGACTTGAGACGTTGACGGACCAATCCCA
CAAGAGCGCTCACATAGCCTGGAGAAGAATGAGGACTCGGGTTTGATCGAGCAGGTGGTTGATACG
CACAAATATTGTCGGATGAAGAAGAGGAGGAGGAGCGATGGGTCGCTTTCGGAGTCTCCGGTCCGG
TGGTCAATGCCGAGGAGATGCCGGCGCAGCCATGTACGAGCTGGTTCGCGTGGACACTCCAGCTAGT
TGGTGAGATCATTGACTGGAGGGTGATATGCCACCATTAGGTTACGAGGATACTCGGGTGTGAGC
GTGGGTGATCCGTCTACCAGACGGGAAAGCCGCTCCGTGGAATTGGGACCCGGCATCATGGCAGCA
TCTCGATGGTATCCAGCGACCATTGAGGTCCA

gi|13762330|gb|BG634793.1|;

AAAAATTGTACCAAGTGA AAAAATTGTATATTTAAACCAAATGGAAAAGAAGTCCTGGGTTGCACCGC
TTACCTCGTTCACCAACAGTAACGCAAGTAACGAAGACAGAGCCCGCAACTCGGGATCGTTAAACCAAGA
GGGGAGCCAAGGTCCGTGCCTCACCCAAACGGTTCCGGCTAAGAAGTGCACATGTCAAACCTGCGCTTG

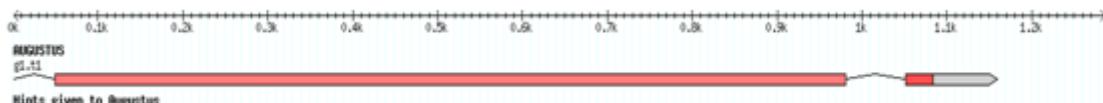
CAACGTAATGACCATAAATCCAATCGGTACCCCTCCCCCTCAATCACGCAAGCCTGTAGCCGAGCCGG
 AAAGTCCCCATGATACTACAGTCATGACGAGGACAGTTGAAGGACTTGAGACGTTGACGGACCAATCCA
 CAAGAGCGCTCACATGCCTTGGAGAAGAACATGAGGACTCGGGTTTGTGATCGAGCAGGTGGTTGATACG
 CACAAATATTGTCGGATGAAGAACAGGAGGAGGAGCAGATGGGTCGCATTTGGAGTCTCCGGTCCGG
 TGGTCAATGCCGAGGAGATGCCGGCGCAGCCATGTACGAGCTGGTTCGCTGGACACTCCCAGCTTGT
 TGGTGGAGATCATTGCACTGGAGGGTGATATGCCACCATTCAAGTTACGAGGATACTTCGGGTGAGC
 GTGGGTGATCCCGTCTACCAGACGGAAAGCCGCTCTCCGTGGAATTGGGACCCGGCATGGCAGCA

gi|13693804|gb|BF496314.2|

AACTTCTGCCCATTTATTGACAATATTAGTAAAAATTGTACCAAGTGAAAAATTGTAT
 ATATTTAATCCAATGGAAAAGAACAGTCCTGGGTCACCGCTTACCTCGTTACCAACAGTAACGAAGAC
 AGAGCCCGCAACTCGGATCGTTAACCAAAGATGGGAGCCAAGGTCCGTGCCTCACCAACGGTCCGG
 CTAAGAAAGTGCACATGTCCAACCTGCCTGCCAACGTAATGACCATAATCCAATCCGTACCCCTCC
 CCCTCAATCACGCAAGCCTGTAGCCGAGCCGGAAAGCCCCATGATACAGTCATGACGAGGACAGTTG
 AAGGACTTGGAGACGTTGCAGGGACCAATCCCACAAGAGCGCTCACATGCCCTGGAGAAGAATGAGGACT
 CGGGTTTGTGATCGAGCAGGTGGTGATACGACAAATATTGTCGGATGAAGAACAGGAGGAGGCGAC
 GATGGGTCGCATTTGGAGTCTCCGGTCCGGTGGTCAATGCCGAGGAGATGCCGGCGCAGCCATGTAC
 GAGCTGGTTCGCGACTCCAGCTAGTTGGTGGAGATCATTGCACTGGAGGGTGATATGCCACCA
 TTCAGGTTACGAGGATACTCGGGTGTGAGCGTGGGTGATCCGTCTACCAGACGGAAAGCCGCTCTC
 CGTGAATTGGGACCCGGCATGGCAGCATCTCGATGGT

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 11 sORFs. Se pueden observar varias repeticiones en tandem y varias desplazadas. La transcripción se basa en la presencia de 10 ESTs en la base de datos pública y la probable traducción en la presencia en bases de datos de un péptido definido por espectrometría de masas que cumpliría con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación. Esto significa que al menos uno de los sORFs codificados por este transcripto es traducido. La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_92



TTGGCGGTCGTGGATATGATTAAATGAAATCCAAAACATAATCAAGGTGGAGATACATTCCACATGT

M_I_L_M_K_S_K_N_I_I_K_V_G_D_T_F_H_M

AGGTCATGGAAATGGTCCAATGCACCTAAAGAACCTCTTAAATCGGAGGAAATATTCAAATGTAGGC

* M_E_M_V_P_M_H_L_K_N_L_L_K_S_E_E_I_F_Q_M *

CAAGGAAACAGGGGTAATAGATATGATCTAAATCCTGAAATCGGAGCAGTCCAGTCGAAATCCTATTG
 CGAATGAAGGCAATGCATTGGCGGTGGATATGATTAAATGAAATCCAAAACATAATCAAGGTGG

M_K_A_M_H_L_A_V_V_D_M_I_* M_K_S_K_N_I_I_K_V_

AAGATACATTCCACATGTAGGTCATGGAAATGGTCCAATGCACCTAAAGAACCTTCTAAAATCGGAGGA
 E_D_T_F_H_M_* M_E_M_V_P_M_H_L_K_N_F_L_K_S_E_E
 AATATTCCCAAATGTAGGCCAAGGAAACAGAGGAAATATATGATCCAAATCGGAAATCGGAGCAGTTC
 _I_F_Q_M_* M_I_Q_I_R_K_S_E_Q_F
 CAGTCGGAATCCTATTCCGAATGAAGGCAATGCATTGGCGGTGCGATGATTAAATGAAATCCA
 _Q_S_E_I_L_F_R_M_K_A_M_H_L_A_V_V_D_M_I_* M_K_S
 AAAACATAATCAAGGTGGAAGATACTTCCACATGTAGGTCATGGAAATGGTCCAATGCACCTAAAGAA
 K_N_I_I_K_V_E_D_T_F_H_M_* M_E_M_V_P_M_H_L_K_N
 CCTCTTAAATCGGAGGAAATATTCCAAATGTAGGCCAAGGAAACAGAGGAAATATATGATCCAAATC
 _L_L_K_S_E_E_I_F_Q_M_* M_I_Q_I
 CGGAAATCGGAGCAGTCCAGTCGGAATCCTATTCCGAATGAAGGCAATGCATTGGCGGTGCGATGATA
 R_K_S_E_Q_F_Q_S_E_I_L_F_R_M_K_A_M_H_L_A_V_V_D
 TGATTTAAATGAAATCCAAAACATAATCAAGGTGGAAGATACTTCCACATGTAGGTCATGGAAATGGT
 M_I_* M_K_S_K_N_I_I_K_V_E_D_T_F_H_M_* M_E_M_V
 CCCAATGCACCTAAAGAACCTTAAATCGGAGGAAATATTCCAAATGTAGGCCAAGGAAACAGAGGGA
 _P_M_H_L_K_N_L_L_K_S_E_E_I_F_Q_M_*
 ATATATATGATCCAAATCGGAAATCGGAGCAGTCCAGTCGGAATCTATTCCGAATGAAGGCAATGC
 M_I_Q_I_R_K_S_E_Q_F_Q_S_E_I_L_F_R_M_K_A_M
 ATTGGCGGTGCGATGATTAAATGAAATCCAAAACATAATCAAGGTGGAAGATACTTCCACAT
 H_L_A_V_V_D_M_I_* M_K_S_K_N_I_I_K_V_E_D_T_F_H_M
 GTAGGTCATGGAAATGGTCCAATGCACCTAAAGAACCTTAAATCGGAGGAAATATTCCAAATGTAG
 * M_E_M_V_P_M_H_L_K_N_L_L_K_S_E_E_I_F_Q_M_*
 GCCAAGGAAACAGAGGAAATAGATATGATCCAAATCGGAAATCGGAGCAGTCCAGTCGGAATCCTAT
 M_I_Q_I_R_K_S_E_Q_F_Q_S_E_I_L
 TCCGAATGAAGGCAATGCATTGGCGGTGCGATGATTAAATGAAATCCAAAACATAATCAAGGT
 F_R_M_K_A_M_H_L_A_V_V_D_M_I_* M_K_S_K_N_I_I_K_V
 GGAAGATACTTCCACATGTAGGTCATGGAAATGGTCCAATGCACCTAAAGAACCTTAAATCGGAG
 _E_D_T_F_H_M_* M_E_M_V_P_M_H_L_K_N_L_L_K_S_E
 GAAATATTCCAAATGTAGGCCAAGGAAACAGAGGTAATAGATATGATCTAAATCCTGAAATCGGACATGC
 _E_I_F_Q_M_* M
 CACATTGGTGCAACCGGTACCGGAATGCAAGGAAATAATAGATAATCCATATAAAACAATCTGGT
 P_H_L_V_Q_P_V_P_E_C_K_E_I_I_*
 GACAGAGCAGAAATGAATTGGAAAGGTTCTCTGAAAATCCCAATAGGGATCATGTTATCAGGCTTA
 M_N_W_K_G_F_L_L_K_I_P_I_G_I_M_L_S_G_L
 GTGATTTTAATCACACGCCACTCCGAGTGCACCTATAA
 _V_I_F_*

Para el gen 2L_92, el programa Augustus Gene Prediction predijo una estructura compuesta por 2 exones de 931 pares de bases el primero, y el segundo de 108 pares de bases, y 1 intrón de 71 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido PHLVQPVPECKEII con una probabilidad de $p=0.028$ y un valor $E=5.29465057429542e-06$.

Se halló evidencia de EST:

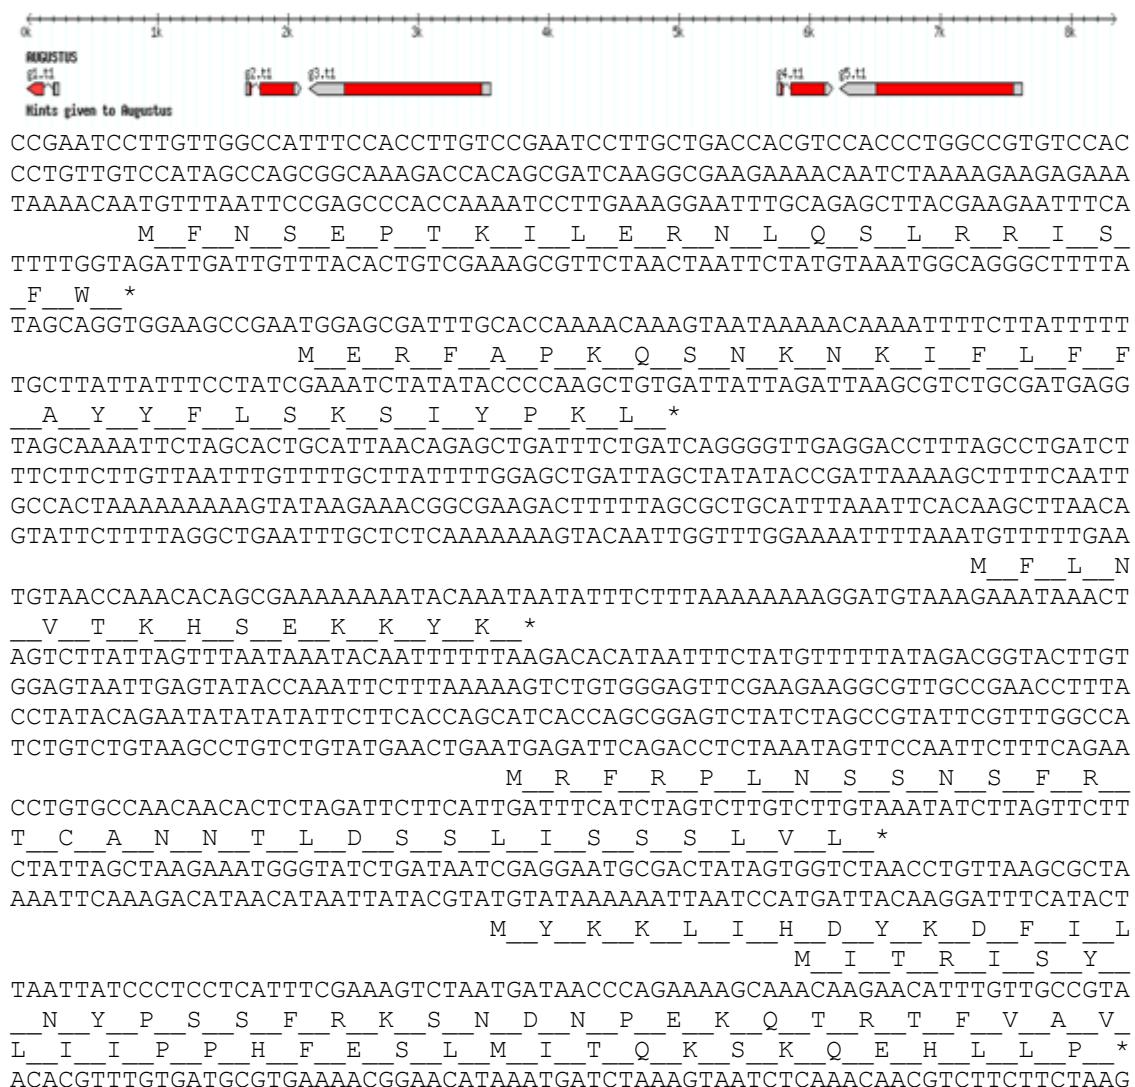
gi|103649946|gb|EC051174.1|

ATGCACCAAATGTGGCATGTCCGATTTCAGGATTAGATCATATCTATTACCTCTGTTCTGGCCTAC
 ATTTGGAATATTCCTCCGATTAAAGAGGTTCTTAGGTGCATTGGGACCATTCCATGACCTACATGT
 GGAATGTATCTTCACCTTGATTATGTTGGATTTCATTAAATCATATCCACGACCGCCAAATGCAT
 TGCCTCATTCCGAATAGGATTCCGACTGGAACTGCTCCGATTTCGGATTGGATCATATCTATTCCC
 TCTGTTCTGGCCTACATTGGAATATTCCTCCGATTAAAGAGGTTCTTAGGTGCATTGGACCA
 TTTCCATGACCTACATGTGGAAATGTATCTCCACCTGATTATGTTGGATTTCATTAAATCATATC
 CACGACCGCCAAATGCATTGCCATTCCGAATAGGATTCCGACTGGAAC TGCTCCGATTCCGGATT
 TGGATCATATATATTCCCTCTGTTCTGGCCTACATTGGAAT

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 19 sORFs. Se pueden observar varias repeticiones en tandem y varias desplazadas. Los sORFs octavo, decimoprimer, decimocuarto y decimoseptimo son repeticiones del segundo sORF. Los sORFs noveno, decimosegundo y decimoquinto son repeticiones del sexto sORF. Los sORFs décimo, decimotercero y decimosexto son repeticiones del séptimo sORF. La transcripción se basa en la presencia de un EST en la base de datos pública y la probable traducción en la presencia en bases de datos de un péptido definido por espectrometría de masas que cumpliría con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación. Esto significa que al menos uno de los sORFs codificados por este transcripto es traducido.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_106



T R L *
 TCGCCCTAGTTCTAGCAACTGTTGGACTTATTAGATTAGGCTGACTTCCCAGATAAGATTGA
 TGTTGAAGGGTCCCCCGTTGAGCATAGGCATTGATACAGTGCTCAAATATTCCCAGACGTCTG
 GAAATTTCGTTGGTTAATTGTACTTGATTTGTCAGAACATTGATAATACTCGGCG
 CGTGACGACATGATGAGATTGAGAGTATAAAAGATCGGAGGCGTCCAAAATTATTACATTAG
 M M R L Q E S I K D R R R P K I L F T L
 CAAGACTAACCGAAGTATCAGCACCATGAAGTTGGTACGTTACATATACGCTTCAAAGAAAAACC
 A R L T E V S A P *
 M K F L V R F T Y T L Q R K T
 TTTAAGAACTAAGTGATTTAATATTGTTACAGATCCTCTTCATTGCCATTGCCGCGCTGCC
 F K N *
 CTACCTCAGTTGGATTGGCGGTGGATTCGGTGATCAGCAGCAGCAAGGAGGATTGGAGGTG
 GATTTGGTGATCAGCAGCAGCAAGGAGGATTGGAGGTGGATTCGGAGGTGGATTCGGTGATCAGCA
 GCAGCAGCAGCAAGGAGGATTGGAGGTGGATTCGGAGGTGGATTCGGTGATCAGCAGCAACAGCAA
 CAAGGCTGGTAAAACCAATTATAGCACCGTCTTAACGAGATACTCAATAAAATATGACACCTTA
 TGATAAAAAACATTGAAATTTTACTTATCGTTCTCGAAAATTATGAGTTTATGAAAATAAATT
 M I K K Q L E F F T L S F S K I Y E F Y E N K F
 M S F M K I N
 TATATTATTATTATTATTATTTATTAAATAGTGCCAGAAATAACACTTAACATAAGGGACAACGG
 I F I I H L Y L L N S A Q K *
 L Y L L F I Y I Y *
 GGAAATATCTCTTCAAGATGTTCAAATGGTTACTTAAACATTGAAATATAAATAAAGCCAAA
 M F K W F Y L K H C K Y K *
 ATATAAAAGCCATATTATAAATATAAGCCAAATTTCACAAAAATTGTTCTTGAAATATGTAAC
 GCAACTAAAAAGCGGATTCAACATGATTGAAAAACAGATAACAATTGAGTATCCTAATCAATGGCCTC
 M I E K T D T I S S I L I N G L
 CTCAGCAGCCACCCCTTGTGCTCCTCGATCTGCACCTTGTCCAGATCGACTCCATCTTTGGCTGCC
 L S S H P F V L L D L H L V Q I D S I F F G C
 CGTATCTCGCCTCCCCCTCCGATCGTAGCTGGTGGCTGCCAACTCCTGTCCACGGCAGTGACA
 P Y L A F P L R S V *
 TCACTGACATGACCTTGACCAGACTGCTATGGTTCTGGCTAGATCACTCTCCCCATTCCCTCCG
 TATTGCTCTGCTCCATCGGCAACTGCAACTCCTCGCAGCACAGCATGGAAATCAGCAAGTGTCAACG
 AAGAGGGTCGCCGAGCCTTGAGATTGTCGTATCGTGGCACTGCACTTTGCTGTGCAATCCACT
 GAAGTAGAACATATCTGTCGTGTTGAATGGCCCCCGGAACCTCAAGCCTAACGCCAGGGACTC
 TGAATTGGCTGCCTCTGGAGGATCATTGTTGCTTAGGAGCTGGGATCGGAGCTCACACGTCCAGTT
 GACAGCCATACGGATATATCGAATATCCTGAATTGGAGTTGCAACTGCGATTGGCGGTGGC
 GCATGTGATTACGGTAAATATTGGCGTAGTGGCGGTGTGGCTCTAGGTAATTGGCGTGTGATCGAT
 M
 GTGGTTGTGCAGGAGATGTTGGAAAGGTGGCTATGCCACCAAGTCCGGCGGCCACAGTCGGCGCAC
 W L C R R C L E R W R M A T S S A A D S P A H
 M F G K V A Y G H Q F G G R Q S G A
 ATGGGGCAGACCACATATTGACACCCGATGTTGAACTGATGTCATGAACTGGGATTCGCT
 M G Q T T Y S L D T R C *
 H G A D H I F I G H P M L N V N M F D E P L R C
 M N R F A
 TGAGCGCAAGTAGGCCGCAATGTGGACAGGTGAAGCAATTGGACAGGTGGACCAGCTGGGATTCGCC
 E R K *
 V S A S R P Q C G Q V K Q L D R W T S S G I S P
 GTAAAGCAGCGAACAGATCGTCCGAGTCAGGGAAACATTGCATGGGATGATTGGCGATGCTCTTCC
 *
 GTTCTATCTGATGATCGTAGCATATGTCACATAGGTTATAGTCACGCGAACACCGGAAGCGGC
 TACCCCTGGAAGATCGTCATTGACAGCCGGTGCAGCAAATGTTGCGGTGACCCATCCTCGATCCTGTG
 TAAACTCGTTCTAGCAATACCTAAACTCTGGTCGAAAAACGGGAAAGGGTTCTAAATTAAAC
 AAATCGAATCTATACAATGACATGATTTCATAGATGAAATATTGGGGCGTTGGTAATAACATAT
 M I F I D V K Y F G A F G N N I
 AATTCTACTTTAAACTATTTCACCTAAATGATCAAACACTCAAGCTTCTACATATTCC
 * M Y Q T Y S S F L H I S F
 TGCCTCTTAAACAAATGTTATTGGAACCTTAAGTACAGCGAAAAAAAGTTAAATAACATGCA
 A S F K Q M F I F G T L S T A K K L N K H A
 M H
 CTGTACTATTGTCGGTGGACAGCTATCAGTGAACAAATAACGATAATGCAATTGTTCCAAA

L Y Y F V R *
 C T I L S G E H S Y L R D K * M Q F V F Q
 CCTATATGAAACGAGAAATAAGCCCCATTATTGATAAGGAACTAAATCTTATCTAAATCTTGACA
 T Y M K R E I S P H Y *
 GTAGAAGATAACTCAAAGGATATTTATTTGCTCAAATCAGAATGCAGTTATCGAAAATTAAACTTCC
 M Q L S K I K L P
 CTTGAGCTGAAAATTAGCTTGAATTATAATTACATATGTCCAATGTAATACAGCTTCAGTGTG
 L S *
 TACACATAAAATTCAAAACCCAAAAAATCCACAAAAATTGCTATTTAGTAGGTATTGCGTTAACACAT
 CGGTTCTAAATGTGGCTGTCATTAGTTACTCTCTGCTCTCGGTTGAATCTCATCTCG
 CTCTCTCTTTAATTCCCAGCTGGCGCAGTTGAATAGAAGTTCCGGCTCATGCACC
 TCCGCCCTGCACCACCCCCCTTCGGCGACCATTGTTGGATTCACTCTAAAATAAGATGTT
 TAATAAACATATAGCAGGTGGAAGCGAATGGAGCGATTGCACCAAAACAAAGTAATAAAACAAATT
 M E R F A P K Q S N K N K I
 TTCTTATTTTGCTTATTATTCCTATCGAAATCTATACCCCAAGCTGTGATTATTAGATTAAGCGT
 F L F F A Y Y F L S K S I Y P K L *
 CTGCGATGAGGTAGCAAATTCTAGCACTGCATTAACAGAGCTGATTCTGATCAGGGTTGAGGACCTT
 TAGCCTGATCTTCTTGTAAATTGTTTGCTTATTGGAGCTGATTAGCTATACGATTAAAA
 GCTTTCAATTGCCACTAAAAAAAAGTATAAGAACGGCGAAGACTTTAGCGCTGCATTAAATTCA
 CAAGCTTAACAGTATTCTTGTGAAATTGCTCTCAAAAAAGTACAATTGGTTGGAAAATTAA
 ATGTTTTGAATGTAACCAACAGCGAAAAAAATACAAATAATTCTTAAAAAAAGGATGTA
 M F L N V T K H S E K K Y K *
 AGAAATAAAACTAGTCTTATTAGTTAATAAATACAATTAAAGACACATAATTCTATGTTTATAG
 ACGGTACTTGTGGAGTAATTGAGTACCAAAATTCTTAAAAAGTCTGTTGGAGTCGAAGAAGGCGTTG
 CGAACCTTACCTACAGAATATATATTCTCACAGCATTACCGCGAGTCTATCTAGCCGTAT
 TCGTTGGCATCTGCTGTAAGCCTGTATGAACTGAATGAGATTCAAGACCTCAAATAGTCAA
 M R F R P L N S S N
 TTCTTCAGAACCTGTGCCAACACACTCTAGATTCTTCATTGATTCATCTAGCTTGTCTTGTAAATA
 S F R T C A N N T L D S S L I S S S L V L *
 TCTTAGTTCTCTATTAGCTAAGAAATGGGTATCTGATAATCGAGGAATGCGACTATAGTGGCTAACCT
 GTTAAGCGCTAAATTCAAAGACATAACATAATTACGTATGTATAAAAATTACATGATTACAAG
 M Y K K L I H D Y K
 M I T R
 GATTTCATACTTAATTATCCCTCCTCATTGAAAGTCTAATGATAACCCAGAAAAGCAAACAGAACAT
 D F I L N Y P S S F R K S N D N P E K Q T R T
 I S Y L I I P P H F E S L M I T Q K S K Q E H
 TTGTTGCCGTAAACGTTGTGATGCGTGAACAGGAACATAATGATCTAAAGTAATCTCAAACACGT
 F V A V T R L *
 L L P *
 CTTCTCTAAAGTCGCCCTAGTTTCTTAGCAACTGTTGGACTTATTAGATTAGGCTCGACTTCCA
 GATAAGATTGATGTTGAAGGGTCCCCCGTTGAGCATAGGATTGATACAGTGTCAAATATTAA
 CCAGACGTCTGAAATTCTCGTATTGTTGGTTAATTGACTTGATTGATTCAGAACATTGATA
 ATACTCGCGCGTGACGACATGATGAGATTGAGGAGGTATAAAAGATCGGAGGCCTTAA
 M M R L Q E S I K D R R R P K I L
 ATTACACATTAGCAAGACTAACCGAAGTATCAGCACCATGAAGTTGGTACGTTACATATACGCTTC
 F T L A R L T E V S A P *
 M K F L V R F T Y T L
 AAAGAAAAACCTTAAGAACTAAGTTAATATTGTTACAGATCCTCTTGTGCGCTATTGCCG
 Q R K T F K N *
 CGGCCGCTGCCCTACCTCAGTTGGATTGGCGGTTGATCAGCAGCAGCAGCAAGGAGG
 ATTTGGAGGTGGATTGGTATCAGCAGCAGCAAGGAGGATTGGAGGTGGATTGGAGGTGGATT
 GGTGATCAGCAGCAGCAGCAAGGAGGATTGGAGGTGGATTGGAGGTGGATTGGTATCAGCAGC
 AGCAACAGCAACAAGGCTGGAAAAACCAATTAGCACCGTCTAACGCAGATACTCAATAAAA
 TGACACCTTATGATAAAAAACATTGAAATTCTTACTTATCGTTCTGAAAATTATGAGTTTAT
 M I K K Q L E F F T L S F S K I Y E F Y
 M S F M
 GAAAATAAATTATTTATTACATTATTTATTAAATAGTGCCAGAAATAACACTAAACAT
 E N K F I F I I H L Y L L N S A Q K *
 K I N L Y L L F I Y I Y *
 AAGGGACAACGGAAATATCTCTTGTGATGTTCAAATGGTTACTTAAACATTGAAATATAAA
 M F K W F Y L K H C K Y K

TAAAAGCCAAATATAAAAGCCATATTATAAAATATAAGCAAATTTCACAAAAATTGTTCTTG
 *
 AAATATGTAACGCAACTAAAAGCGGATTCAACATGATTGAAAAACAGATAACAATTGAGTATCCTAA
 M_I_E_K_T_D_T_I_S_S_I_L
 TCAATGGCCTCCTCAGCAGCCACCCTTTGTCTGCATCTGCACCTGTCCAGATCGACTCCATCTT
 I_N_G_L_L_S_S_H_P_F_V_L_L_D_L_H_L_V_Q_I_D_S_I_F
 TTTTGGCTGCCGTATCTGCCCTCCCCCTCCGATCCGTCTAGCTGGTGGCTGCCAAACTCCTGTCCA
 F_G_C_P_Y_L_A_F_P_L_R_S_V_*
 CGGCAGTGACATCACTGACATGACCTGACCAGACTGCTATGGTTTCTGGTCTAGATCACTCTCCCCA
 TTTCTTCCCCTTCGCTCTCCATCCGGCAACTGCAACTCCTCGCAGCACAGCATGGAAATCAGCA
 AGTGTCAACGAAGAGGGTTGCCGCAGCCTTGAGATTGTCGTATCGTGGACTGCACCTTTGCTG
 TGCAATCCACTGAAGTAGAACATATCTGCGTCGTGTTGAATGGCCCCCGGAACCTAAGCCTAAC
 GCCAGGGACTCTGAATTGGCTGCCCTCTGGAGGATCATTGTTGCTTAGGAGCTGGGATCGGAGCTCA
 CACGTCCAGTTGACAGCCATACGGATATATCGAATATCCTGAATTGGAGTTGTCACACTGCGATTG
 GCGGTGGTGGCGATGTGATTACGGTAAATATTGGCGTAGTGGCGTGTGTCGGCTCTAGGTAATTG
 GCGTGATCGATGTGGTGTGAGGAGATGTTGAAAGGTGGCGTATGCCACCAAGTCGGCGGCCGACA
 M_W_L_C_R_R_C_L_E_R_W_R_M_A_T_S_S_A_A_D
 M_F_G_K_V_A_Y_G_H_Q_F_G_G_R_Q
 GTCCGGCGCACATGGGGCAGACCACATATTGACACCCGATGGTAAACATGTTGATGAA
 S_P_A_H_M_G_Q_T_T_Y_S_L_D_T_R_C_*
 S_G_A_H_G_A_D_H_I_F_I_G_H_P_M_L_N_V_N_M_F_D_E
 M_N
 CCGCTTCGCTGTGAGCGCAAGTAGGCCGAATGTGGACAGGTGAAGCAATTGGACAGGTGGACCAGCTCT
 P_L_R_C_E_R_K_*
 R_F_A_V_S_A_S_R_P_Q_C_G_Q_V_K_Q_L_D_R_W_T_S_S
 GGGATTTCGCCGTAAAGCAGCGGAACAGATCGTCCGAGTCAGGAACAATTGATGGATGATTGGCGC
 G_I_S_P_*
 GATGCTCTTCCGTTCTATGATGATCGTAGCATATGTCACATAGTTATAGTTACGCAGCGCAAACA
 CCGGAAGCGGCTACCTGGAAAGATCGTACCTGGACAGCCGTTGCAGCAAATGTTGCGGTGACCCATCTC
 GATCCTTGTGCTAACCTCGTTAGCGAATATACCTAAACTCTGGTCAAAAAACGGGCAAAGGGTTC
 TAAATTAAACAAATCGAATATACATGACATGATTTCATAGATGAAATATTGGGGCGTTG
 M_I_F_I_D_V_K_Y_F_G_A_F_G
 TAATAACATATAATTCTACTTTAAAATTTCAACCTAAATGTATCAAACCTACTCAAGCTTTCTA
 N_N_I_*
 M_Y_Q_T_Y_S_S_F_L
 CATATTTCTTGCCTCTTTAAACAAATGTTATTTGGAACCTTAAGTACAGCGAAAAAAAGTTAA
 H_I_S_F_A_S_F_K_Q_M_F_I_F_G_T_L_S_T_A_K_K_L
 ATAAACATGCACTGACTATTGTCGGTGAGCACAGCTACGTGACAAATAACGATAATGCAATT
 N_K_H_A_L_Y_Y_F_V_R_*
 M_H_C_T_I_L_S_G_E_H_S_Y_L_R_D_K_*
 M_Q_F
 TGTTTCCAAACCTATATGAAACGAGAAATAAGCCCCATTATTGATAAGGAACAAATCTTCTAA
 V_F_Q_T_Y_M_K_R_E_I_S_P_H_Y_*
 ATCTTTGACAGTAGAAGATAACTCAAAGGATATTATTTGCTCAAATCAGAATGCAGTTATCGAAA
 M_Q_L_S_K
 ATTAAACTCCCTGAGCTGAAAATTAGCTGAATTATAATTACATATGTCACAAATGTAATACAGC
 I_K_L_P_L_S_*
 TTCAGTGTGTGACACATAAAATTCAAACCCAAAAATCCACAAAATTGCTATTAGTTAGGTATTGC
 GTGAACACATCGGTTCTAAATGTGGCTGTTGCCATTAGTTACTCTTCTGTCTGTCTGGTTGAA
 TCTCCATCTCGCTCTTCTTTAAATTCCGACTTGGTGCAGGCTGTAATAGAAGTTTCCGG
 CTTCATGCACCTCCGCCCTGCACCAACCCCTTCGGCGACCATTTGGTGGATTAGTACACTCTAAA
 ATAAGATGTTAAACATATAGCAGGTGGAAGCGAATGGAGCGATTGACCAAAACAAAGTAATA
 M_E_R_F_A_P_K_Q_S_N
 AAAACAAAATTTCCTATTGCTTATTACCTATCGAAATCTATACCCCAAGCTGTGATTATT
 K_N_K_I_F_L_F_F_A_Y_Y_F_L_S_K_S_I_Y_P_K_L_*
 AGATTAAGCGTCTGCATGAGGTAGCAAATTCTAGCACTGCATTAACAGAGCTGATTCTGATCAGGGG
 TTGAGGACCTTAGCCTGATCTTCTTGTAAATTGTTGCTTATTGGAGCTGATTAGCTATAT
 ACCGATTAAGCTTCAATTGCCACTAAAAAAAGTATAAGAAACGGCGAAGACTTTAGCGCTGC
 ATTAAATTCAACAGTATTCTTGTGACATTGCTCTAAAAAGTACAATTGGTTG
 GAAAATTAAATGTTGAATGTAACCAAACACAGCGAAAAAAATACAATAATTCTTAA
 M_F_L_N_V_T_K_H_S_E_K_K_Y_K_*
 AAAGGATGTAAGAAATAACTAGTCTTATTGTTAAATAACAAATTGACACATAATTCTA
 TGTTTATAGACGGTACTTGTGGAGTAATTGAGTACCAAAATTCTTAAAGTCTGTGGAGTCGA

AGAAGGCCTGCCAACCTTACCTATACAGAATATATATTCTCACCAAGCATCACAGCGGAGTCTA
 TCTAGCCGTATTCGTTGGCATCTGTCTGTAAGCCTGTCTGTATGAATGAGATTCACTCTA
 M_R_F_R_P_L
 AATAGTTCCAATTCTTCAGAACCTGTGCCAACACTCTAGATTCTCATTGATTCTAGTCTTG
 N_S_S_N_S_F_R_T_C_A_N_N_T_L_D_S_S_L_I_S_S_L
 TCTTGTAATATCTTAGTTCTATTAGCTAAGAAATGGGTATCTGATAATCGAGGAATGCGACTATAG
 V_L_*
 TGGTCTAACCTGTTAAGCGCTAAAATTCAAAGACATAACATAATTACGTATGTATAAAAATTAATCC
 M_Y_K_K_L_I
 ATGATTACAAGGATTCATACTTAATTATCCCTCCTCATTCGAAAGTCTAATGATAACCCAGAAAAGCA
 H_D_Y_K_D_F_I_L_N_Y_P_S_S_F_R_K_S_N_D_N_P_E_K_Q
 M_I_T_R_I_S_Y_L_I_P_P_H_F_E_S_L_M_I_T_Q_K_S
 ACAAGAACATTGTTGCCGTAAACACGTTGTGATGCGTAAAAACGGAACATAATGATCTAAAGTAATC
 T_R_T_F_V_A_V_T_R_L_*
 K_Q_E_H_L_L_P_*
 TCAAAACAACGTCTCTTCAAGTCGCCCTAGTTTCTTAGCAACTGTTGCGGACTTATTAGATTAGGC
 TCGACTTCCCAGATAAGATTGATGTTGAGGGTTCCCCCGTTGAGCATAGGCATTGATACTGCTCAA
 ATATTAATTTCCCAGCTGGAAATTTTCTGTTGGGTTATTGACTTGATTTGTCA
 GAACATTGATAATACCGCGCGTGAACATGATGAGATTGAGGAGAGTATAAAAGATCGGAGGC
 M_M_R_L_Q_E_S_I_K_D_R_R_R
 CCAAAATTTTATTACATTAGCAAGACTAACCGAAGTATCAGCACCATGAAGTTGGTACGTTTAC
 P_K_I_L_F_T_L_A_R_L_T_E_V_S_A_P_*
 M_K_F_L_V_R_F_T
 ATATACGCTCAAAGAAAAACCTTAAGAAACTAAGTGATTTAATATTGTTACAGATCCTCTTCAATTGC
 Y_T_L_Q_R_K_T_F_K_N_*
 CCTATTGCCGCCGCTGCCCTACCTCAGTTGGATTGGATTCGGGATTCGGTGTACAGCAGCAGCAG
 CAGCAAGGAGGATTGGAGGTGGATTGGTGTACAGCAGCAGCAGCAAGGAGGATTGGGAGGTGGATT
 GAGGTGGATTGGTGTACAGCAGCAGCAACAGCAACAGCTGGTAAAACCAATTGACACCCTTAACGCAGATA
 CAATAAAATATGACACCTTATGATAAAAAACAATTGGAATTTTACTTATCGTTCTGAAATT
 M_I_K_K_Q_L_E_F_F_T_L_S_F_S_K_I
 ATGAGTTTATGAAAATAATTATATTATTATTCAATTATTTATTAAATAGTGCCTACAGAAATAAAT
 Y_E_F_Y_E_N_K_F_I_F_I_I_H_L_Y_L_L_N_S_A_Q_K_*
 M_S_F_M_K_I_N_L_Y_L_L_F_I_Y_I_Y_*
 ACACCTAACATAAGGGACAACGGAAATATCTCTTCAAGATGTTCAAATGGTTTACTAAAACATT
 M_F_K_W_F_Y_L_K_H
 GTAAATATAAAAGCCAAATATAAAGCCATTATAAATATAAGCCAAATTTCACAAAAATT
 C_K_Y_K_*
 GTTTTCTTGTAAATATGTAACGCAACTAAAAGCGGATTCAACATGATTGAAAAAACAGATA
 M_I_E_K_T_D_T_I_S
 GAGTATCCTAACATGGCCTCCTCAGCAGCCACCCCTTTGTGCTCCTCGATCTGACCTTGCCAGATC
 S_I_L_I_N_G_L_L_S_S_H_P_F_V_L_L_D_L_H_L_V_Q_I
 GACTCCATTTGGCTGCCGTATCGCCTCCCCCTCGATCCGTAGCTGGTTGGCTGCCAA
 D_S_I_F_F_G_C_P_Y_L_A_F_P_L_R_S_V_*
 ACTCCTGCCACGGCAGTGACATCACTGACATGACACTGCTGAGCAGACTGCTATGGTTCTGGCTAGAT
 CACTCTCCCCATTCCCTCCCGTATTCGTCTGTCCATCCGGCAACTGCAACTCCTCGCAGCACAGCAT
 GGAAATCAGCAAGTGCTAACGAAGAGGGTCGCCGAGCCTTGAGATTGCTCCGTAGCTGGCACTGC
 ACTTTTGCTGTGCAATCCACTGAAGTAGAACATATCTGTCGTCGTGTTGAATGGCCCCCGGAAC
 TCAAGCTAACGCCAGGGACTCTGAATTGGCTGCCCTCTGGAGGATATTGTCGTTAGGAGCTGGGG
 ATCGGAGCTCACACGTCAGTTGACAGCCATACGGATATATCGAATATCCTGAAATTGGAGTTGTTGC
 AACTGCGATTGGCGGTGGTGGCGATGTGATTACGGTAAATATTGCCGTAGTGGCGGTGTCGGGCT
 CTAGGTAATTGGCGTGTGATGTGGTGTGCAAGGAGATGTTGGAAAGGTGGCGTATGCCACCAAGTTC
 M_W_L_C_R_R_C_L_E_R_W_R_M_A_T_S_S
 M_F_G_K_V_A_Y_G_H_Q_F
 GCGGGCCGACAGTCCGGCGCACATGGGCAGACCACATATTGACACCCGATGTTGAACGTAAACA
 A_A_D_S_P_A_H_M_G_Q_T_T_Y_S_L_D_T_R_C_*
 G_G_R_Q_S_G_A_H_G_A_D_H_I_F_I_G_H_P_M_L_N_V_N
 TGTCGATGAACCGCTCGCTGTGAGCCAGTGGCGCAATGTGGACAGGTGAAGCAATTGGACAGGT
 M_F_D_E_P_L_R_C_E_R_K_*
 M_N_R_F_A_V_S_A_S_R_P_Q_C_G_Q_V_K_Q_L_D_R
 GGACCAGCTCTGGATTTCGCCGTAAAGCAGCGAACAGATCGTCCGAGTCAGGAAACAATTGCATGG

W_T_S_S_G_I_S_P_*
 ATGATTGGCGCGATGCTTCCGTTCTATGATGATCGTAGCATATGTCACATAGGTTATAGTCACG
 CAGCGAAACACCGGAAGCGGCTACCCTGGAAGATCGTCATTGACAGCCGTTGCAGCAAATGTTGCGGT
 GACCCATCCTCGATCCTGTGCTAACTTCGTTCTAGCGAATATACTAAACTCTGGTCGAAAAAACGGG
 CAAAAGGGTTCTAAATTAAACAATCGAATCTATACAATGACATGATTTCATAGATGTAAAATATTTC
 M_I_F_I_D_V_K_Y_F
 GGGCGTTGGTAATAACATATAATTCTACTTTAAAATTTTCAACCTAAATGTATCAAACCTACT
 G_A_F_G_N_N_I_* M_Y_Q_T_Y
 CAAGCTTCTACATATTCCCTTGCCCTTTAAACAAATGTTATTTTGGAACCTTAAGTACAGCGAA
 S_S_F_L_H_I_S_F_A_S_F_K_Q_M_F_I_F_G_T_L_S_T_A_K
 AAAAAAGTTAAATAACATGCACTGTACTATTTGCCGGTGAGCACAGCTATCTACGTGACAAATAACG
 K_K_L_N_K_H_A_L_Y_Y_F_V_R_*
 M_H_C_T_I_L_S_G_E_H_S_Y_L_R_D_K_*
 ATAATGCAATTGTTCCAAACCTATATGAAACCGAGAAATAAGCCCCATTATTGATAAGGAACAAAT
 M_Q_F_V_F_Q_T_Y_M_K_R_E_I_S_P_H_Y_*
 CTTTTATCTAAATCTTGACAGTAGAAAGATAACTCAAAGGATATTATTTGCTCAAATCAGAATGC
 M
 AGTTATCGAAAATAAACTCCCTTGAGCTGAAAATTAGCTGAATTATAATTACATATGTCCAAA
 Q_L_S_K_I_K_L_P_L_S_*
 TGTAATACAGCTTCAGTGTGTGACACATAAAATTCAAAACCCAAAAATCCACAAAAATTGCTATTTA
 GTAGGTATTGCGTTGAACACATCGGTTCTAAATGTGGCTGTTGCCATTAGTTACTCTCTGT
 CTCGGTTGAATCTCCATCTCGCTCTTTAATTTCGGACTTGGTGCAGCGCAGTTGTAATAG
 AAGTTTCCGGCTTCATGCACCTCCGCCCTGCACCACCCCTTCGGCGACCATTGGTGGATTCACT
 ACACCTTAAAGATGTTAATAACATATAGCAGGTGGAAGCCGAATGGAGCGATTGACCAAA
 M_E_R_F_A_P_K
 ACAAAAGTAATAAAACAAAATTCTTATTGCTTATTATTCCTATCGAAATCTATATAACCCAAAG
 Q_S_N_K_N_K_I_F_L_F_F_A_Y_Y_F_L_S_K_S_I_Y_P_K
 CTGTGATTATTAGATTAAGCGTCTCGCATGAGGTAGCAAATTCTAGCACTGCATTAAACAGAGCTGATT
 L_*
 CTGATCAGGGTTGAGGACCTTAGCCTGATCTTCTTGTAAATTGTTTGCTTATTGGAGCTG
 ATTAGCTATACCGATTAAAGCTTCAATTGCCACTAAAAAAAGTATAAGAAACGGCGAAGACTT
 TTAGCGCTGCATTAAATTCAAGCTAACAGTATTCTTGTGAAATTGCTCTCAAAAAAGTA
 CAATTGGTTGGAAAATTAAATGTTTGAAATGTAACCAAACACAGCGAAAAAAATAACAAATAATAT
 M_F_L_N_V_T_K_H_S_E_K_K_Y_K_*
 TTCTTAAAAAAAGGATGTAAGAAATAACTAGCTTATTAGTTAATAAAATACAATTGTTAAGACA
 CATAATTCTATGTTTATAGACGGTACTTGTGGAGTAATTGAGTATACAAATTCTTAAAGCTG
 TGGGAGTCGAAGAAGGGCGTTGCCAACCTTACCTATACAGAATATATATTCTCACCAGCATCACC
 AGCGGAGTCTATCTAGCCGTATTGCTTGGCCATCTGTCTGTAAGCCTGTATGAACGAGATGAGAT
 M_R
 TCAGACCTCTAAATAGTCCAATTCTTCAGAACCTGTGCCAACACACTCTAGATTCTCATTGATTTC
 F_R_P_L_N_S_S_N_S_F_R_T_C_A_N_N_T_L_D_S_S_L_I_S
 ATCTAGTCTTGCTTGTAAATATCTTAGTTCTTCTATTAGCTAACAGGATCTGATGATAATCGAGGAA
 S_S_L_V_L_*
 TGCGACTATAGGGCTAACCTGTTAACGCTAAAGACATAACATAATTACGTATGTATAA
 M_Y_K
 AAAATTAATCCATGATTACAAGGATTCATACTTAATTATCCCTCCTCATTCGAAAGTCTAACATGATAAC
 K_L_I_H_D_Y_K_D_F_I_L_N_Y_P_S_S_F_R_K_S_N_D_N
 M_I_T_R_I_S_Y_L_I_I_P_P_H_F_E_S_L_M_I_T
 CCAGAAAAGCAAACAAAGAACATTGCTGCGTAACACGTTGTGATGCGTGAACACGGAACATAATGAT
 P_E_K_Q_T_R_T_F_V_A_V_T_R_L_*
 Q_K_S_K_Q_E_H_L_L_P_*
 CTAAGGTAATCTAAACACGCTTCTTCTAACAGTGCCTTAGTTCTTAGCAACTGTTGGGACTTA
 TTAGATTAGGCTGACTTCCCAGATAAGATTGATGTTGAAAGGGTCCCCCGTTGAGCATAGGCATTGAT
 ACAGTGTCAAATATTAATTCCAGACGTCTGAAATTTCGTTGTGATGAGATTGAGGAGATGAGGAGAT
 TGATTTGTCAGAACATTGATAATACCGCGCGTACGACATGATGAGATTGAGGAGATGAGGAGAT
 M_M_R_L_Q_E_S_I_K
 ATCGGAGGCGTCCAAAATTTCACATTAGCAAGACTAACCGAACAGTATCAGCACCATGAAGTTTG
 D_R_R_R_P_K_I_L_F_T_L_A_R_L_T_E_V_S_A_P_*
 M_K_F_L
 GTACGTTTACATATACGCTTCAAAGAAAAACCTTAAAGAAACTAACAGTGTGATTTAATATTGTTACAGATC
 V_R_F_T_Y_T_L_Q_R_K_T_F_K_N_*

CTCTTCATTGCCCTATTGCCCGCCGCTGCCCTACCTCAGTTGGATTGGCGGTGGATCGGTGATC
 AGCAGCAGCAGCAAGGAGGATTGGAGGTGGATTGGTGTACAGCAGCAGCAAGGAGGATTGG
 CGGTGGATTGGTGTACAGCAGCAGCAACAGCAACAGCAAAAGGCTGGTAAAACCAATTCA
 CGCAGATAACCTCAATAAAAATATGACACCTTATGATAAAAAAACATTGGAATTTTACTTATCGTT
 M_I_K_K_Q_L_E_F_F_T_L_S_F
 CTCGAAAATTATGAGTTTATGAAAATAAATTATTTATTATTATTCAATTATTTATTAAATAGTGCC
 S_K_I_Y_E_F_Y_E_N_K_F_I_F_I_I_H_L_Y_L_L_N_S_A
 M_S_F_M_K_I_N_L_Y_L_L_F_I_Y_I_Y_*
 CAGAAATAAATACACTAACATAAGGGACAACGGGAAATATCTTCTCTTCAGATGTTCAAATGGTTTA
 Q_K_* M_F_K_W_F_Y
 CTTAAAACATTGTAATATAAATAAAAGCCAAATATAAAAGCCATTATAAAATATAAGCCAATTTC
 L_K_H_C_K_Y_K_*
 ACAAAAATTGTTTCTTGAAATATGTAACGCAACTAAAAGCGGATTCAACATGATTGAAAAAAC
 M_I_E_K_T
 GATACAATTTCGAGTATCCTAATCAATGGCCTCCTCAGCAGCCACCCTTGTGCTCCTCGATCTGCACC
 D_T_I_S_S_I_L_I_N_G_L_L_S_S_H_P_F_V_L_L_D_L_H
 TTGTCCAGATCGACTCCATTTGGCTGCCGTATCTGCCCTCCCCCTCGATCGTCTAGCTGGT
 L_V_Q_I_D_S_I_F_F_G_C_P_Y_L_A_F_P_L_R_S_V_*
 TGGTCTGCCAAACTCCTGTCCACGGCAGTGACATCACTGACATGACCTTGACCAGACTGCTATGGTTTC
 CTGGTCTAGATCACTCTCCCATTTCCTCCGTATCGTCTGTCTCCATCGGCAACTGCAACTCCTCG
 CAGCACAGCATGAAATCAGCAAGTGCTCAACGAAGAGGGTCGCCGCAGCTTGAGATTGTCGT
 CGTGGCACTGCACTTTGCTGTGCAATCCACTGAAGTAGAACATATCTGTCGTGTCGATGG
 CCCCCCGGAACCTAACGCTAACGCCAGGGACTCTGAATTGGCTGCCCTCTGGAGGGATATTGCT
 AGGAGCTGGGGATCGGAGCTCACAGTCCAGTTGACAGCCATACGGATATATCGAATATCCTGAATTG
 GAGTTGTTGCAACTGCGATTGGCGTGGCGCATGTGATTACGGTAAATATCGCGTAGTGGCG
 TGTGTCGGGCTCTAGTAATTGGCGTGTGAGATGTTGGAAAGGTGGCGTATG
 M_W_L_C_R_R_C_L_E_R_W_R_M
 M_F_G_K_V_A_Y
 GCCACCAGTCGGCGGCCGACAGTCCGGCGCACATGGGGCAGACCACATATTGACACCCGATGTT
 A_T_S_S_A_A_D_S_P_A_H_M_G_Q_T_T_Y_S_L_D_T_R_C
 G_H_Q_F_G_G_R_Q_S_G_A_H_G_A_D_H_I_F_I_G_H_P_M_L
 GAACGTAACATGTTGATGAACCGCTTCGCTGTGAGCGCAAGTAGGCCGCAATGTTGACAGGTGAAGCA
 *
 N_V_N_M_F_D_E_P_L_R_C_E_R_K_*
 M_N_R_F_A_V_S_A_S_R_P_Q_C_G_Q_V_K_Q
 ATTGGACAGGTGGACAGCTCTGGATTTCGCCGTAAAGCAGCGGAACAGATCGTCCGAGTCAGGGAAC
 L_D_R_W_T_S_S_G_I_S_P_*
 ATTGCATGGATATTGGCGCATGCTTCTTCTATCTGATGATCGTAGCATATGTCACATAGGT
 TATAGTTACCGCAGCGCAAACACCGGAAGCGGCTACCCCTGGAAGATCGTCAATTGACAGCCGTTGCAGCA
 ATGTTGCGGTGACCCATCCTCGATCCTGTGCTAACCTCGTTAGCGAATATACCTAAACTCTGGTC
 GAAAAAACGGCAAAGGGTCTAAATTAAACAAATCGAATCTACACATGACATGATTTCATAGATG
 M_I_F_I_D_
 TAAAATATTGCGGGCGTTGGTAATAACATATAATTCTACTTTAAAATATTCAACCTAA
 V_K_Y_F_G_A_F_G_N_N_I_*
 ATGTATCAAACCTACTCAAGCTTCTACATATTCCCTTGCCTTTAAACAAATGTTATTGGAA
 M_Y_Q_T_Y_S_S_F_L_H_I_S_F_A_S_F_K_Q_M_F_I_F_G
 CCTTAAGTACAGCGAAAAAAAGTTAAATAACATGCACTGTACTATTGTCGGTGAGCACAGCTATC
 T_L_S_T_A_K_K_L_N_K_H_A_L_Y_Y_F_V_R_*
 TACGTGACAAATAACGATAATGCAATTGTTCCAAACCTATATGAAACGAGAAATAAGCCCCATTAT
 M_Q_F_V_F_Q_T_Y_M_K_R_E_I_S_P_H_Y
 TGATAAGGAACTAAATCTTTATCTAAATCTTGACAGTAGAGATAACTCAAAGGATATT
 *
 GCTCAAATCAGAATGCAGTTATGAAAATTAAACCTCCCTGAGCTGAAAATTAGCTGAATT
 M_Q_L_S_K_I_K_L_P_L_S_*
 TATACATATGTCCAAATGTAATACAGCTCGTGTACACATAAAATTCAAAACCAAAAAATCCACAAAAA
 TTGCTATTAGGTATTGCG

Para el cluster de sORFs 2L_106, el programa Augustus Gene Prediction predijo, para el gen 1.1, una estructura compuesta por 2 exones de 125 pares de bases el primero y el

segundo de 34 pares de bases, y 1 intrón de 86 pares de bases; para el gen 2.1 predijo una estructura de 2 exones, el primero de 41 pares de bases y el segundo de 314 pares de bases, y un intrón de 68 pares de bases; para el gen 3.1 predijo una estructura de un exón de 1394 pares de bases; para el gen 4.1 predijo una estructura de 2 exones, el primero de 42 pares de bases y el segundo de 314 pares de bases, y un intrón de 68 pares de bases; para el gen 5.1 predijo una estructura de un exón de 1393 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido FRPLNSSNSFRTCANNTLDSSLISSLVL con una probabilidad de $p=0.042$ y un valor E=4.2191514764815e-05; para el péptido FNSEPTKILER con una probabilidad de $p=0.042$ y un valor E=3.30202273667463e-07.

Evidencia de ESTs:

gi|133847614|gb|EL881080.1|;

```
CTCTTTCAGATGTTCAAATGGTTTACTTAAACATTGAAATATAAATAAAAGCCAAATATAAAGCC
ATATTATAAATATAAGCCAAATTTCAACAAAATTTGTTTCTTGAAATATGTAACGCAACTAAAAA
GC GGATTCAACATGATTGAAAAAACAGATAACAATTGAGTATCCTAATCAATGGCCTCCTCAGCAGCCA
CCCTTTGTGCTCTCGATCTGCACCTGTCAGATCGACTCCATCTTTGGCTGCCGTATCTGCC
TTCCCCCTCGATCCGCTAGCTGGTTGGTCTGCCAAACTCCTGTCCACGGCAGTGACATCACTGACATG
ACCTTGACCAGACTGCTATGGTTTCTGGTCTAGATCACTCTCCCATTCCCTCCGTATTCGTCTGT
CTCCATCCGGCAACTGCAACTCCTCGCACAGCATGGAAATCAGCAAGTGCTAACGAAGAGGGTTCG
CCGCAGCCTTGAGATTGTCGTATCGTGGCACTGCACCTTGCTGTGCAATCCACTGAAGTAGAAC
TATCTGTCGTCGTGTTGAATGGCCCCCGGAACCTAACGCTAACGCCAGGGACTCTGAATTGGCTG
CCTCCTCTGGAGGATCATTGCTTAGGAGCTGGGATCGGAGCTCACACGTCCAGTTGACAGCCATAC
GGATATATCGAATATCCTGAATTGGAGTTGTCAGACTGCGATTG
```

gi|133847726|gb|EL881190.1|;

```
GAAATATGTAACGCAACTAAAAGCGGATTCAACATGATTGAAAAAACAGATAACAATTGAGTATCCTA
ATCAATGGCCTCCTCAGCAGCCACCCCTTTGTCCTCGATCTGCACCTTGTCCAGATCGACTCCATCT
TTTTGGCTGCCGTATCTGCCCTCCCCCTCGATCGTCTAGCTGGTTGGTCTGCCAAACTCCTGTCC
ACGGCAGTGACATCACTGACATGACCTTGACCAGACTGCTATGGTTTCTGGTCTAGATCACTCTCCC
ATTCCTCCCGTATCGTCTGTCCATCCGGCAACTGCAACTCCTCGCAGCACAGCATGGAAATCAGC
AAAGTGCACAGAAGAGGGTCGCCGAGCCTTGAGATTGTCGTATCGTGGCACTGCACCTTGCT
GTGCAATCCACTGAAGTAGAACATATCTGTCGTCGTGTTGAATGGCCCCCGGAACCTAACGCTAA
CGCCAGGGACTCTGAATTGGCTGCCTCTGGAGGATCATTGCTTAGGAGCTGGGATCGGAGCTC
ACACGTCCAGTTGACAGCCATACGGATATATCGAATATCCTGAATTGGAGTTGTCAGACTGCGATT
GGCGGTGGTGGCGATGTGATTACGGTAAATATTGGCGTAGTGGCGGTGTGTCGGCTCTAGGTAATT
GGCGTGATCGATGTGGTTGTGCAGGAGATGTTGGAAAGTGGNGTATG
```

gi|133847951|gb|EL881415.1|;

```
ATGTCATTGATAGATTGATTGTTAAAATTAGAACCCCTTTGCCGTTTTCGACCAGAGTTAGG
TATATTGCTAAGAACGAAAGTTAGCACAAGGATCGAGGATGGGTACCGCAACATTGCTGCAACGGCTG
TCAAATGACGATCTCCAGGGTAGCCGCTCCGGTTGCGCTGCGTGAACATAAACCTATGTGACATA
TGCTACGATCATCAGATAGAACGGAAGAGCATCGGCCAATCATCCATGCAATTGTCCTGACTCGG
ACGATCTGGTCCGCTGTTACGGCAAATCCAGAGCTGGTCCACCTGTCCAATTGCTTCACCTGTCC
ACATTGCGGCCTACTTGCCTCACAGCGAAGCGGTTATCGAACATGTTACGTTCAACATCGGCGTCC
AATGAATATGTGGTCTGCCCATGTGCGCCGGACTGTCGGCCCGAACCTGGTGGCCATACGCCACCTT
CCAAACATCTCCTGCACAACCACATCGATCACGCCAATTACCTAGAGCCGACACACCACACTACGCC
AATATTACCGTAATCACATGCGCACCACGCCAATCGCAGTTGCAAACAACCTCGAATTCAAGGATA
TTCGATATATCGTATGGCTGTCAACTGGACGTGTGAGCTCCGATCCCAGCTCCTAAGCAACAATGATC
CTCCAGAGGAGGCAGCCAATTCAAGAGTCCCTGGCGTTAG
```

gi|133847727|gb|EL881191.1|;

```
CAGAGTTAGGTATATTGCTAAGAACGAAAGTTAGCACAAGGATCGAGGATGGGTACCGCAACATTG
TGCAACGGCTGTCAAATGACGATCTCCAGGGTAGCCGCTCCGGTTGCGCTGCGTGAACATATAACC
TATGTGACATATGCTACGATCATCAGATAGAACGGAAGAGCATCGGCCAATCATCCATGCAATTGTT
```

CCCTGACTCGGACGATCTGGTCCGCTGCTTACGGCGAAATCCCAGAGCTGGTCCACCTGTCCAATTGC
TTCACCTGTCCACATTGCGGCCACTTGCGCTCACAGCGAAGCGGTCATCGAACATGTTACGTTCAAC
ATCGGGGTGTCATGAATATGTGGTCTGCCCATGTGCGCCGGACTGTCGGCCGCCAAGTGGTGGCCAT
ACGCCACCTTCCAAACATCTCCTGCACAACCACATCGATCACGCCATTACCTAGAGCCCACACACCG
CCACTACGCCAATATTACCCGAATCACATGCCACCAGGCCATCGCAGTTGCAAACAACTCCGA
ATTCAAGGATATTGATATATCCGTATGGCTGCAACTGGACGTGTGAGCTCCGATCCCCAGCTCTAAG
CAACAATGATCCTCCAGAGGAGGCAGCCAATTCAAGTCCCTGGGTTAGGCTTAGGAGTTCCGGGGCCA
TTCGAACACCACGACAGATATGT

gi|133847950|gb|EL881414.1|;

GAAATATGTAACGCAACTAAAAAGCGGATTCAACATGATTGAAAAAACAGATAACAATTGAGTATCCTA
ATCAATGGCCTCCTCAGCAGCCACCCTTGTGCTCCTCGATCTGCACCTTGTCCAGATCGACTCCATCT
TTTTGGCTGCCGTATCTGCCCTCCCCCTCGATCCGTCTAGCTGGTTGGCTGCCAAACTCCTGTCC
ACGGCAGTGACATCACTGACATGACCTTGACCAGACTGCTATGGTTTCCCTGGTCTAGATCACTCTCCCC
ATTCCTCCCGTATCGTCTGTCTCCATCGGCAACTGCAACTCCTCGCAGCACAGCATGGAAATCAGC
AACTGCTCAACGAAGAGGGTTCGCCGCAAGCTTGAGATTGTCGTATCGTGGCACTGCACTTTGCT
GTGCAATCCACTGAAGTAGAACATATCTGTCGTCGTGTTGAATGCCCGGGAACTCAAGCCTAA
CGCCAGGGACTCTGAATTGGCTGCCTCTGGAGGATCATTGTTGCTTAGGAGCTGGGATCGGAGTTC
ACACGTCAGTTGACAGCCATACCGATATATCGAATATCCTGAATTGGAGTTGTTGCAACTGCCATT
GGCGTGGTGGCGATGTGATTA

gi|14692315|gb|BI214591.1|;

ATTACACATTAGCAAGACTAACCGAAGTATCAGCACCATGAAGTTTGATCCTCTTCATTGCCCTATTG
CCGCGCCGCTGCCCTACCTCAGTTGGATTGGCGGTGGATTGGTGTACAGCAGCAGCAGCAAGG
AGGATTGGAGGTGGATTGGTGTACAGCAGCAGCAAGGAGGATTGGCGGTGGATTGGAGGTGG
TTCGGTGTACAGCAGCAGCAGCAAGGAGGATTGGAGGTGGATTGGAGGTGGATTGGAGGTGG
AGCAGCAACAGCAACAAGGCTGGTAAAACCAATTGACAGCACCGTCTAACGCAGATACTCAATA
ATATGACACCTTATGATAAAAAACAAATTGAAATTTTTACTTTATCGTTCTCGAAAATTATGAGTT
TATGAAAATAATTATTTATTATTATTATTATTAAATAGTGCCAGAAATAACACTTAA
CATAGGGACAACGGGAAATATCTCTTCAAGATGTTCAAATGGTTACTTAAACATTGAAATAT
AAATAAAAGCCAAATATAAAAGCCATTATAAAATATAAGCCAAAAAAAAAAAAAA

gi|14639167|gb|BI173360.1|;

ATTCCATTAGCAAGACTAACCGAAGTATCAGCACCATGAAGTTTGATCCTCTTCATTGCCCTATTG
CGCGCCGCTGCCCTACCTCAGTTGGATTGGCGGTGGATTGGTGTACAGCAGCAGCAGCAAGG
GGATTGGAGGTGGATTGGTGTACAGCAGCAGCAAGGAGGATTGGCGGTGGATTGGAGGTGG
TCGGTGTACAGCAGCAGCAGCAAGGAGGATTGGAGGTGGATTGGAGGTGGATTGGAGGTGG
GCAGCAACAGCAACAAGGCTGGTAAAACCAATTGACAGCACCGTCTAACGCAGATACTCAATA
TATGACACCTTATGATAAAAAACAAATTGAAATTTTTACTTTATCGTTCTCGAAAATTATGAGTT
ATGAAAATAATTATTTATTATTATTATTAAATAGTGCCAGAAATAACACTTAA
ATAAGGGACAACGGGAAATATCTCTTCAAGATGTTCAAATGGTTACTTAAACATTGAAATATA
AAATAAAAGCCAAATATAAAAGCCATTATAAAATATAAGCCAAAAAAAAAAAAAA

gi|133847615|gb|EL881081.1|;

GTAAAATTAGAACCCCTTTCGCCGTTTCGACCAGAGTTAGGTATATCGCTAACAGAACAGTTA
GCACAAGGATCGAGGATGGGTCAACCGAACATTGCTGCAACGGCTGTCAAATGACGATCTCCAGGGTA
GCCGCTTCCGGTGTGCGCTGCGTGAACATAACCTATGTGACATATGCTACGATCATCAGATA
GAAAGAGCATCGGCCAATCATCCCATGCAATTGTCCTGACTCGGACGATCTGGTCCGCTGCTTAC
GGCAGGAACTCCAGAGCTGGTCCACCTGTCCAATTGCTTCACCTGTCCACATTGCGCTACTT
CAGCGAACGCGGTCATCGAACATGTTACGTTAACATCGGGTGTCCAATGAATATGTGGTCTGCC
GTGCGCCGGACTGTCGGCCGCCAAGTGGTGGCCATACGCCACCTTCAAACATCTCTGCA
ATCGATCACAGCGAACGCGGTCATCGAACATGTTACGTTAACATCGGGTGTCCAATGAATATGTGGT
TGCCCCATGTGCGCCGGACTGTCGGCCGCCAAGTGGTGGCCATACGCCACCTTCAAACATCTCTG
ACAACCACATCGATCACGCCATTACCTAGAGGCCACACCCGCACTACGCCAATATTACCGTAA
TCACATGCGCCACCACCGCCAATCGCAGTTGCAAACAACTCCGAATTCAAGGATATTGATATCCGTA
TGGCTGTCAACTGGACGTGGAGCTCCGATCCCCAGCTCTAAGCAACAATGA

gi|114061072|gb|BP556658.1|;

TTTTTTTTTTTTTTTTTTTTTTTTTTTACAAAAATTGGCTTATATTATAATATGGCT

TTTATATTTGGCTTTATTATTTACAATGTTAAGTAAAACCATTGAACATTGAAAGAAAAAA
 TATTCCCGTTGCCCTATGTTAAGTGTATTCTGGGCCTATTAAATAATAATGAATAAT
 AAATATAAATTATTTCATAAAACATCAAATTTCGAGAACGATAAAGTAAAAATTCCAATTGTTT
 TTTATCATAAAGGGTCATATTATTGAGGTATCTGCCTTAAACGGGCATGAATTGGTTTAC
 AGCCTGTTGCTGCTGCTGATCACCGAATCCACCTCGAATCCACCTCCAATCCTCCTGCTG
 CTGCTGCTGATCACCGAACCTCCGAATCCACCGCAAATCCTCCTGCTGCTGCTGATCA
 CCAAATCCACCTCAAATCCTCCTGCTGCTGCTGATCACCGAACCTCCGAATCCACTTC
 CAAATCCTCCTGCTGCTGCTGATCACCGAACCTCACC

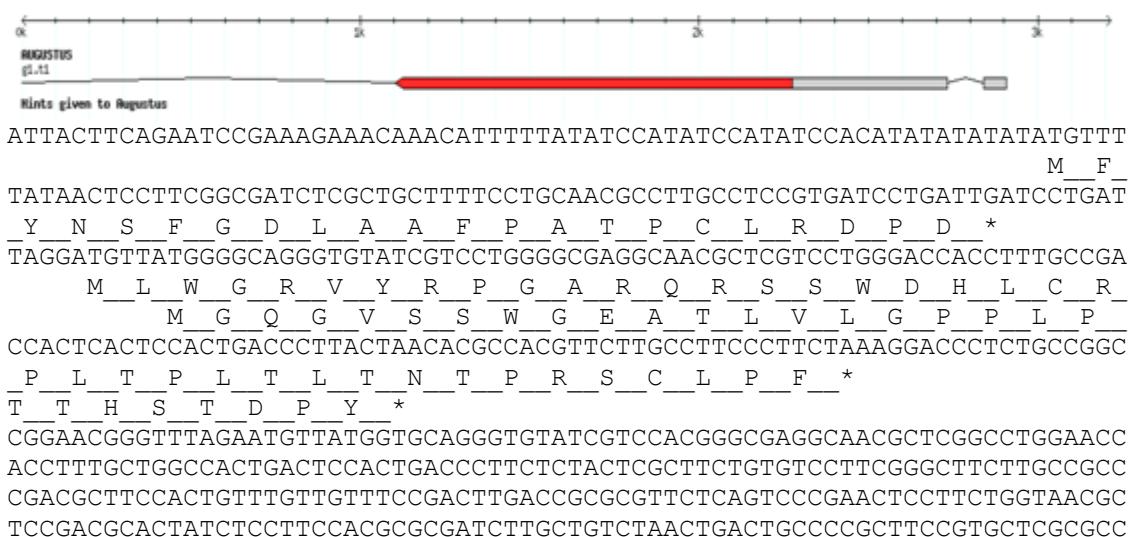
gi|114061073|dbj|BP556659.1|

GATTCACATTAGCAAGACTAACCGAAGTATCAGCACCATGAAGTTTGATCCTCTTCATTGCCCTATT
 GCGCGGCCGCTGCCCTACCTCAGTTGGATTGGCGGTGGATTGGCGGTGATCAGCAGCAGCAGCAG
 AAGGAGGAGTTGGAAGTGGATTGGAGGTGGATTGGCGGTGATCAGCAGCAGCAGCAAGGAGGAGTTGG
 AGGTGGATTGGTGTGATCAGCAGCAGCAAGGAGGAGTTGGAGGTGGATTGGAGGTGGATTGGTGTGAT
 CAGCAGCAGCAGCAAGGAGGAGTTGGAGGTGGATTGGAGGTGGATTGGTGTGATCAGCAGCAGCAAC
 AGCAACAAGGCTGGTAAAACCAATTCAAGCACCGTCTAACGCAGATACTCAATAAAATATGACAC
 CTTTATGATAAAAAACATTGAAATTTTACTTTATCGTTCTCGAAAATTATGAGTTTATGAAAAT
 AAATTATATTTATTTCATTATTTATTAAATAGTGCCAGAAATAAACACTTAACATAAGGGA
 CAACGGGAAATATCTCTTCAGATGTTCAAATGGTTTACTTAAACATTGTTAAATATAATAAAAG
 CCCAAATATAAAGCCATATTATAAATA

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 77 sORFs. Se pueden observar varias repeticiones. La transcripción se basa en la presencia de 10 ESTs en la base de datos pública y la probable traducción en la presencia en bases de datos de 2 péptidos definidos por espectrometría de masas que cumpliría con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación. Esto significa que al menos 2 de los sORFs codificados por este transcripto son traducidos.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_1



TTTTATAGGCCGCAAGGATCCTGCATCCTCTCAGCCTCACGTCTAGCCTGCCGTTAGGCATCTGAC
 GGGCATCTTGACCCTCACATCCTCTCCGTTCTCCTCTGTCCCTCGCGGTCTCTTCACCTCTAT
 CTGCTGCTGCTGCTGCTCACCAGTCGATATTGAATTTCGGCCTTCACCGCTCAT
 CAATTTCGGCCTGGCAACATTGCCAACCTCGTATCGATATCGTAGGCGCGTTGCCACTTCGCT
 TCTCCGGGCTCTCCTCGGCTCGCCTATTGGGCTCCTCTCCGGCTCTATCTGCTGCT
 GGGCGTAGCCGCCGATCGCTTCCGCTCCCTCCAGACACGGGCTCCGGCGCTCTGGCCTCCAT
 CGACGCGGGCACGTCACGACGGACTTTGTGCCACAGACGCCCTCCCATCTGACCCTGCGGACC
 ACCTGTCGACGTGCTGCTGAGAATCTCCCACGCCGCTCTGTATACCGTGGGCTCTCCCCCTCCT
 GGGTGGTGGCGTCAGCAGGGCGCTCGCAGGGTTATCGTGGTGTGGTGGCGGTGACTGCGT
 TGGCGGCGGCGTGTGGCAACCGCTCTGCCATGCCATGGCGTGGCGACCTTCGCGCATC
 M_R_P_W_R_R_R_P_F_A_H
 CACCATCTGAAACGCCGAGGGTGGCGACTCGCCATCCATGAATCTCTCATGCCACCGGATCCTCG
 P_P_S_G_N_A_A_G_W_R_L_A_H_P_*
 M_N_L_F_M_S_T_G_S_S
 GTCGGCGGAGCGACTCCGAGGCTTATCGTCCCTGGCCCTGGTAGGCCGCGAGGCTTCGGTAAGCCA
 V_G_G_A_T_P_R_L_I_R_P_W_P_C_V_A_R_R_R_L_R_*
 TCCGCGGGTCTCATCCTCGATGACACCTCCGGGGTGGACCGTCTGCCTCCGTCGTCTCCTC
 ACTCTCGAAGAGAGGGTGATGACCTCAGCCGCCCTGTATCCGCATCGGTTGGTCTCCTTAAGT
 M_T_S_A_A_P_S_V_S_A_I_G_W_S_S_L_S
 TCCACGTCCCGAATTCTCACACTCCCCGGGGTGGAGATCGCGACACCAGGGGTGACGCCAGGAGCT
 S_T_S_G_I_S_S_T_L_P_G_G_D_R_D_T_R_G_D_A_R_S
 GGAGATAGGAATCGGAATCCATATTCCATATGCCCGGGTGTGCGCTATCGCTGCTTCCTGCCT
 W_R_*
 GACCTGGTCCGCCAGATATGTCATGAAACCTCTAGGCAGGAAAAATCTGGAAGACCCATGTCTCCCAG
 M_S_P_R
 AATTGTTGGCAATAACCACTCAAGGCCCTGCCCGTAGTAGTTCGCATCGCTCTGGATCT
 I_C_C_W_Q_*
 GGTTGATGTCGATTCCATATGTCATTGCTGACCATTCCAGCTGCTCTAGGAACCTCAGCGGCTTCGTT
 M_S_L_L_T_I_P_A_A_L_G_T_S_A_A_S_R
 CCCGCGTAACGAAACTCCACTCACGACCTGTTGCCACCTTGCCTAGTCCTGCGGTGCTGGCCTT
 S_R_R_N_G_N_S_T_H_A_P_V_S_P_P_L_R_S_P_A_V_L_A_L
 GCGGTCTCCCGCCTATCCGGCTGACTTCCTGCCCTCCTCTTCGCGGCTGCCGTCTGGCCT
 R_S_P_A_Y_P_G_*
 GTCCGATTTCTGCCTTCAGACCTGCTCCGCTGGCTCTGCCATTCTAGCGAAGTCGGGCTCTCAC
 CAGGCCCTCTACGCCGGTGAATTCAACTCTACGCCGGTCTCCTCCATACTCCTTTCCAGGGCTTCT
 ATAATTGCGACAGATTCCGGCTCATCTGTTGCTGGTGAACACTGGACAACGTCTTCGATTTCT
 M_N_S_D_N_V_F_R_I_S
 CCACCAAACCTCCAGTTATCCGAGTGTATCTTCTCAAGCTGATAGCCACGACTGCCATCT
 S_T_K_P_S_S_F_I_P_S_V_I_F_L_Q_A_V_*
 TGCTCTGCTTCCCTTTGCCCGGACAATCACGCTGGCGCCAGATGTAACGAACTGATTTCTTATT
 GCTCGCTACGGATTGCACTGGCTGCTCAGAGAGTTTGCGTTCCACCAAATTATGATTGTGT
 M_I_C_V
 GATTGCCGATCACGGAAAAGCAATGGGTTCTTAGTATAGTATTCTACAGCCTATGGATAACTT
 I_A_R_S_R_K_S_N_G_F_L_V_*
 M_D_N_F
 CCTCGGCAATCTCGGTGCTACTGCCGCTTCTCGCAACGCCCTGCCGTGGCCTGCT
 F_G_N_L_G_A_T_A_A_F_L_L_Q_R_L_A_S_V_V_L_L_A_P
 TGACACGGACGACGACGGTTAGGGTGTATCGCTCGGGCGAGGCAAACGCTCGCTGGGACCA
 *
 CTTTGCCGACCACTGACTCCACTGTCCTTCGAACACGCTACGCTTATCGTCTCCTCTGGAAGACCA
 CCTGCCGGTGGTATGGGTTAGGATTATTATGGGGCAGGGTATATCGCCTCGGGCGAGGCAAACGCTCG
 TCCTGGGCCACCTGTACCGACCACTGACTCCTCACCCCTACGAACACGCCAAGTTCTGCCTCC
 TCGGAACGTCCTCTGCCGGCGGAACGGGTTAGGATTTGAGTATGGTGCAGGGTGTATGTC
 M_V_Q_G_V_S_S_T_G_E
 GGCAACGCTCGGCCTGGAACCAACCTTGCTGCCACTGACTCCACTGACCCCTTGACACGCTAGATCC
 A_T_L_G_L_E_P_P_L_L_A_T_D_S_T_D_P_F_*
 TTCTCCTCCACTCCCAGGATCTCCTCGCTGTGGTGTATCGCCTCCATGTCCTCGGGCTTGC
 GCCAGACGTTCCACTGTTGGTATTCACCGACCTGACTCCTCACCCGAACCTTCAGTTAA
 CGTTCTGATGCACTGTCCTCCACTCGCAGTCTGGCTGGCGTACTGAATGACCCATCCG
 M_H_V_L_L_P_L_A_I_W_L_A_D_*

Para la región genómica 2R_1, el programa Augustus Gene Prediction predijo una estructura compuesta por 2 exones de 1629 pares de bases el primero y 66 pares de bases el segundo, y un intrón de 108 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido
MSLLTIPAAALGTSASA con una probabilidad de $p=0.057$ y un valor
 $E=0.000525837993509083$.

Evidencia de ESTs:

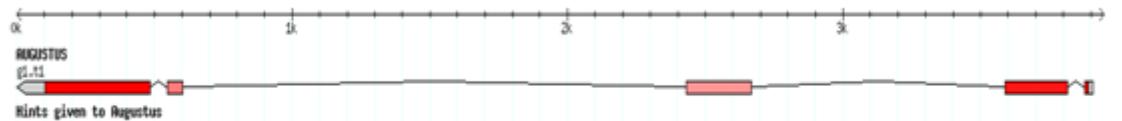
gi|10609532|gb|BE978250.1;
GCACGAGACGGTACAGATGGTCCCAGGCCGAGCGTTGCCCGCCGTGGACGATAACCATGCTCCATAA
CACCTAAACCCATACCGACTGGCAGGTAGTCTTCAGCGCAGACGACAGCGACATAGCGGGTCGAGAG
GGACAGTGGAGTCAGTGGTGGCAAGGTGGTCTCCTGACGAGCATTGTCTGCCCGCAGGACGATAACCC
CTGCCCTATAACATCCTAGTCCGGCCGGCGACTCGTCGTCTGGTCAAGAAGCAATCAGGACCACGG
AGGCAAGGCAGTGCAGGAAAAGCAGCAGGAGCAGCAGGAGATCGCCGAATTATATATAAACAGTA
GAATAAACGGCTATCATANGAAAAAAAAAAAAAA

gi|13690304|gb|BF498414.2;
CTAGAACCAACCAATTCTAAAATTAACTATTCAACACTGTGAGGAGTCTAAACTCCTTACAAATCTCG
CGTAGGGAGTGGCCTAGCAACAGCCGGTGCAGGGCAAAGCGGAAAGACCGTGAATTAACGGTACCGC
TGTGGACCTTGGACTCCAGCGGCCAAGGGAGGGCAGGTCGAACGGTGACGGTGCGTGAGCAAGGAGGAC
GCACCGTGAATTAACGGCACAATATGTGGACCTTGTACCCGAGCGGGCCGTGCGCAAAAAGAGAAATAGC
GGGATCCCTGCGGCTATAAAGGGTAGGCAGCAGGATGAGAGGCAGTTAGTGAGACAGAAAGGTG
CGCACGAAAGAACAGAGCGTCGCACTGTTAACCGAAGGAGTCCGAAGTGAAGAACCGCGGTCAAGTC
AGAAGGAAAGGCACAGTGGAAAGCATCGGGCGCAAGAACGCCCCAAGGACACCGAAGGACGGTACCCACAA
GCAGGTAGAGAACCTTGGAGTGGAGGAGAAGGCAGTGTCAAGGATCAGTGGAGTCAGTGGCCAGCAAAG
GTGGTAAACGGCTATAATAAGAACCAATTGCTTTCTGGTCAAGGAAATCACAAAATCTAAATTGGT
GGGGCGAACGCACAAACTCTGAGCTAGCGCTGCAATCCGTAGCGAGCAGAACATAAGAAAATCAGTTG
TTACATCTGGCGCTAACCGTATTGTCCGGCAAAAGGAAACAGAGCAAGAT

gi|133845428|gb|EL878894.1|
TCTCATCAGAAATTAAATGAAATTAAATTATCCATATTGTATTCTGTGCAACTAGTGTAAAAGTTTCA
ATTCAAAAATCAATTCAAGAGTTCAAGTGTGAGCCTTCCGACCAGAGAGCGCCTCTGCTCTCAGGGATTG
CCAAACACAGTCCAACAAAGACCCCTAGAATAACCTAGAAGACCCCTAGAATAGCTGAAGCAATACGAA
AAGAGTGTCTCAAATTGCAAGATAACAGACAAATTACGGCAGAACAAATTATGGTAAATTACCAACGCA
AAGGATTACATTAATAACTGGAGTAAACTACCGGGGCCATATCATATAAGGTGCTAACAAATCGTAAT
CAGAAATCGTATAAGGGTTATACTCCTGGAGTGGAGGAGAAGGATCTGGCGTTCAAAAAGGGTCAGTG
GAGTCAGTGGCCAGCAAAGGTGGACCCAGGG

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 13 sORFs. La transcripción se basa en la presencia de 3 ESTs en la base de datos pública y la probable traducción en la presencia en bases de datos de un péptido definido por espectrometría de masas que cumpliría con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación. Esto significa que al menos uno de los sORFs codificados por este transcripto es traducido. La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_2



TAACAATTGCGTGTATTTACAAACAGTACGATTACTTAAGCTAATAGTCGAAAGGTCTCGGGGAACA
GTCCGTAGTGCATCCGCTTCATAGAGGTTCTAGTGATGACGGGGTGCCTGGGTGCTGGTGGTGGGA
CTCCAGGCCAGGCGACGGCGCGGGCGATGGCCTCTGGGATTGGAGGAGGAGTGGGGATCCAGGCTCCCGAG
GGCTGGTATCCGTTCTCATTGGCGACGTACTTAACCTCGACGTGCTCGCCCTCGGGTGGAGATCCAGCCGA
AGTTGCCGTGGATGTTGCCATGGGCATACCGCTGGCGCTGCTCGATTCCGTTGGAGGTGTGCAGGCT
M_G_I_T_A_G_G_L_L_D_S_V_G_G_V_Q_A
GGAATCGAACATCCATCGGCACGAACATCATCGGATTGGGAAAGGACATCGCGTGGACATCCTCGAACGG
G_I_E_S_I_G_T_N_I_I_G_L_G_K_D_I_G_V_D_I_L_R_T
CCTAGGGAAATGGGGCACCGGGGGTTGGCCACCGGCCAGGCCAAAATGCGCAGATCATGACCTGAAGGA
A_* M_G_H_R_G_V_G_H_R_Q_A_Q_N_C_A_D_H_D_L_K_E
GAAATAGGCATTGTTAGGGATCGAGTATGTTGGTCTGATCCTGCGGACACTTACAAACTGAAACATAT
K_* M_L_V_R_I_L_R_T_L_T_N_L_N_I
TGGCTGACTTCTGTCGGTCAGAACGAAACGTTGACTGATAACTGATTGTTGCTGGCAGAGCCTTTTA
L_A_D_F_C_L_V_E_N_E_R_*
TATGATTGCCACCCAAAGTGAACCCATATCAAACGCTACATCTGCATTCAATTGGTCGCTGAGTTAT
GGGTTGACTTCGCGGATGCGCCCACACCCATTAAAAAGCATCGTCACATGCGACAGCTTAGCAAATGCCA
M_R_Q_L_S_K_C_Q
M_P_
AACAAACGGGATAAAGTACTATATATAATCGCTTAATAGATGCTAAATGAAACAATCGCATCAATAAGGGG
T_T_G_*
N_N_G_I_S_T_I_Y_N_R_L_I_D_A_K_M_K_Q_S_H_Q_*
CAAACGGGTGGCATCCGAAATCGAAACGAGTTGACCCGCCCCCTCATTAAATCCCTCCTTG
AGCTTGACTTGGCATTGCCAGGCCGTGAACCACCTTTGTAGTCCCATCAAGACTCCATGGACTACAAAGC
M_D_Y_K_A
ATGCCGACTTCTAGACTCGATGTTGTAATATATAAACGTGTCTACCTGGCACCATTTCTC
S_P_T_S_*
TTTTTTTATCAATTCTCGACGAACAGGTTGAGTTGCTTTAAACAAATTCAAGTGTGTTTACA
TTATATTTCATATGCATAGGCCATTATTTTATATTTCGTAAAATTAAAGATAATAAGAC
M_H_S_A_L_Y_Y_F_F_I_F_R_K_I_K_*
CTGTTCCATATAGGAGGCTACCGAAATACATAGTTTTAGTGACAATTAAAGTTAAGAAAACCTAA
TGTAAACCTAAAGAGGATATTACTTGTCTGATAGGCATATAAAACTAAAGTTACTTAAATTATAA
TTCCTATAGATACATTCATGGTATTTAAATGTGCAAGCCGAACATCTAATATAAGAGCTTGAATAGTT
M_V_F_K_C_A_S_R_T_S_N_I_R_A_*
GTTTTCAGATCAGTTAGACCGCACAGTATCCTCACAAATTGGTTGAAAGTTAAGATTATTGTAAT
CAAACAGAATAGCCTTCTGAGATTATGCTAGTGACTATCGCACCTTAACAATCCAAGCTCTAATA
M_L_V_T_I_A_P_L_T_I_Q_A_S_N
TTAACTGTTGTGACGAAAATAGAGTTTATTCAACTAAGACAATACATCTAAAGTTACTCGTTCG
I_N_C_C_D_E_N_R_V_F_I_Q_L_R_Q_Y_N_I_*
GGACGCTTATGACATTATTGAGGTGCATTGAGACAGACAAACAAACAAATTCCCAGTC
TTATTTAAAAAGAGAGAATGCTACTCAGCTGGAAAGTGTGACCGATATTTCAATACTTTGAAT
M_L_Y_S_A_G_S_V_T_D_I_F_Q_Y_F_F_E
ATCGGTAAAAATTGGAAACAAATAATAATGAAAAAAATTATTGAATTGTTCAAAACGTGTGGCGTG
Y_R_* M_K_K_I_I_E_L_F_K_T_C_G_R
GCAGTTTAGGCCGTTGTGGCCTCTGGAATCTCATATCATCTAAACTCTAGTTTGAAG
G_S_F_R_P_F_V_G_L_W_N_L_H_I_*
TCGAGGCGTTCATACGGACATACTCTGCTATTGATCGCTTAAATATATAACTTATATGGTGTGA
AACGCCTCCTCTACCTGTTACATAATTTCCTAGTATTCCATTTCAGTAACGGGTATTATCA
TTTCAGTTATCTCGTATGTTTATCTCATTCTTCTAGATTATTTACGGTCAATCTCTTACT
TTTATGCTGCCTTCTATTGGTATCACACAATAATAAGACAACACAGCAGATAGAAGTTGCTTT
GTACTCTGGTGCCTCGTCACTACGTGGAATGCCGTTCATGGTATTCTCTTTGAAACCA
M_P_F_M_V_I_L_L_S_F_*
TTTACTTATGTCGGTAAAAACTTATTGAATAATATAACATGTCGATGGAAAGTCGGTGGATGGGT
M_S_M_E_S_R_W_M_G
CTGAGATCGGGGTGAAGAGTCTGGTATGGTGCAGGCCGTCAGTGGAAACGCCCTCGGG
L_R_S_G_* M_V_R_M_L_G_Y_R_S_V_E_R_L_R
ATTGGTGCAGGAGTCGGAATCAAGGCTGATCGAAGCCTGGTATCGTACCGTACGTGACC

D_W_C_R_S_R_N_Q_G_*
TCGACGTGATGCCCTCGGGGGTGAATTTAGTGCCTGAAAATACCATCGATATCTGCTTG
CGGCCGCTGATTCCGTTGAATATGTGCAGACTGCTGGAATCGAATCCATCGGTATAAACATCGTATGA
M_C_R_L_L_E_S_N_P_S_V_* M
TTGGTAGTGGACATCGCGTTGCACTTCGAAACGTCCTACGGATGGGGATGGGGATGAGCCACTCA
I_G_S_G_H_R_R_C_H_F_R_N_V_L_R_M_G_D_G_G_*
M_G_D_E_P_L_ M_S_H_S_
ATCCAAAAACTGCACAGATCACACGTGAACGAGAGCATAGACATTGAATACTGTTCGTATCCTGCCGTTA
N_P_K_T_A_Q_I_T_T_*
I_Q_K_L_H_R_S_P_R_E_R_E_H_R_H_*
CTCACGAGCATGAACATTTAGATTCCAATTCTGTTGCTGAGAACGAAACGTTGACTGATAACCACCA
M_N_I_L_D_S_N_F_C_L_L_E_N_E_R_*
AAACTGAACCCAAGTCATAACGCTACATCTTCATACGATTGGTGCTGAAATCTGGTTGACTATGAA
GATACCCCACACCCATTAAAAGCATCGCATGGCAATCCACGGGATTAGTACTACGAGTATATACTAGGG
M_A_I_H_G_I_S_T_T_S_I_Y_*
TAATCGGCTCGTGGCATTGACCATTGCTTTCTATTCAATAAGTTGTCATTGGTATTGGCTCTC
TAATTGGCTTTAAATACTACTAAATAAAAAAAAAATGCATTGAGACTTTAGTGAGAATAAAATTGT
ATGCAAACATTGCTTTTGTTTCAAGATCTTAGACTGCCAGATCCTCTCAAATTAAAAGAC
M_Q_T_F_A_F_L_F_R_S_F_R_L_P_R_S_F_S_N_F_K_R_
AAAATTAAATTTCAGCACATCTTCTTATGGACACATATACTCATTGATAATGGATTAA
Q_N_*
GTGAATCGAATATAAAAGGTAGAAGGAAGCATTCCAGCGAAGGTAGAGGTATAAAAGCTCGTATTATTA
CAGGAACCTAAAGTGAATGAAGAACACACATTTACTGCTATAAGCAAGTGCATGTATT
M_K_N_T_H_I_F_T_A_I_S_K_C_M_Y_F_
TTGAAAGTCAGAACAGCTAAACAATTGGCGATTGTTGGGAGAACAGTCCGTGGAGTGGC
F_E_S_Q_E_V_Q_L_N_N_L_G_D_L_F_R_E_N_S_P_W_S_G_
CGGGATCCGGGTGACGAGTCCTAGTGATGACGGGGTGCTGGGTGAGACTCCAGCCAG
P_G_S_G_*
CAACGGCGCGGGCGATGCCCTCTGGGATTGGAGGAGTGGGATCCAGGCTCCGAGGGCTGGTATCC
GTTTCATTGCGACGTACTTACCTAACGTGCTGCCCTGGGTGAGATCCAGCCGAAGTTGCCGTGG
ATGTTGCCATGGCATCACCGCTGGCGCTGCTGATTCCGTTGAGGTGTCAGGCTGGAGTCGAATC
M_G_I_T_A_G_G_L_L_D_S_V_*
CGTCGGCACGACGTCGTCCGATGGAAAGGACATCAGCGTGTACATCATCGGAGCGGGAAACTGGGGC
TAGGGCGGTAGCCACTCCCACACGGCGAGAATCATCACCTGGATAGAGGAAATGATA
CGAGTTCATAAATGTCCTGTGAGCCACTCACAAACTGAAACATGTTGGCTGATTCTGTGAGAA
M_S_C_E_P_L_T_N_L_N_M_L_A_D_F_C_L_V_E_N
CGAACGTTGACTGATAACTGACTTGGTC
E_R_*

Para la región genómica 2R_2, el programa Augustus Gene Prediction predijo una estructura compuesta por 5 exones de 482 pares de bases el primero, 55 pares de bases el segundo, 235 pares de bases el tercero, 229 pares de bases el cuarto, y 27 pares de bases el quinto, y 4 intrones de 65 pares de bases el primero, 1829 pares de bases el segundo, 921 pares de bases el tercero, y 63 pares de bases el cuarto.

Se encontró acuerdo con espectros de masas para el péptido LIDAKMK con una probabilidad de $p=0.035$ y un valor $E=0.000668890167392407$; y para el péptido MLGYRSVER con una probabilidad de $p=0.059$ y un valor $E=5.70180330807161e-06$.

Se halló evidencia de ESTs:

gi|48954582|gb|CO181701.1;
GAAATCAGCCAACATGTTCAAGTTGTGATGATTCTGCCGTTGGAGTGGCTACCGCCCTAGCCCCA
GTTTCCCGCTCGATGATGTACACGCTGATGTCCTTCCGATCGGACGAGCTCGTGGCGACGGATTG
ACTCCAGCCTGCACACCTCAAACGGAATCGAGCAGGCCAGCGGTGATGCCATGGCAACATCCACGG
CAACTTCGGCTGGATCTCACCCGAGGGCGAGCACGTTGAGGTAAAGTACGTGCGAATGAAAACGGATAC
CAGCCCTCGGGAGCCTGGATCCCCACTCCTCCAATCCCAGAGGCCATGCCCGCCGTGCTGGC

TGGAGTCTCACCCCCCAGCACCCGAGCACCCCGTCATCACTAGGACTCGTCACCCGGATCCCGGACCAC
TCCACGGACTGTTCTCCGAAACAAATGCCAAGTTGTTAGCTGTACTTCTTGACTTTCAAAAAAATA
CATGCACTTGTTATAGCAGTAAAAAAAAAAAAAATTAGAGCGGCCGCTTAGAGGATCCAA
GCTTACGTACCGTGCATGCGACGTACAGC

gi|41402352|gb|CK658827.1|;

CTCGACCAGACAGAAATCAGCCAACATGTTCAAGTTGTGATGATTCTGCCGTTGAGTGGCTAC
GCCCTAGCCCCAGTTCCCGCTCGATGATGTACACGCTGATGTCCTTCCGATCGGACGACGTTCGTG
CCGACGGATTGACTCCAGCCTGCACACCTCAAACGGAATCGAGCAGGCCAGCGGTGATGCCATGG
CAACATCCACGGCAACTCGGCTGGATCTCACCCGAGGGCGAGCACGTTGAGGTAAGTACGTCGCAAT
GAAAACGGATAACCAGCCCTCGGGAGCCTGGATCCCCACTCCTCCTCAATCCCAGAGGCCATGCCCGCG
CCGTTGCCCTGGCTGGAGTCTCACCCCCCAGCACCCGAGCACCCCGTCATCACTAGGACTCGTACCCGG
ATCCCCGACCACTCCACGGACTGTTCTCCGAAACAAATGCCAAGTTGTTAGCTGTACTTCTTGACT
TTCAAAAAAATACATGCACTTGTTATAGCAGTAAAAAAAAAAAAA

gi|38623711|gb|CK131775.1|;

GTTCGTTCTCGACCAGACAGAAATCAGCCAACATGTTCAAGTTGTGATGATTCTGCCGTTGAGTGGAGT
GGCTACCGCCCTAGCCCCAGTTCCCGCTCGATGATGTACACGCTGATGTCCTTCCGATCGGACGAC
GTTCGTGCCGACGGATTGACTCCAGCCTGCACACCTCAAACGGAATCGAGCAGGCCAGCGGTGATG
CCCAGGCAACATCCACGGCAACTCGGCTGGATCTCACCCGAGGGCGAGCACGTTGAGGTAAGTACGT
CGCGAATGAAAACGGATAACCAGCCCTCGGGAGCCTGGATCCCCACTCCTCCTCAATCCCAGAGGCCATC
GCCCGCGCCGTTGCCCTGGAGTCTCACCCCCCAGCACCCGAGCACCCCGTCATCACTAGGACTCGT
CACCCGGATCCCGGACCACTCCACGGACTGTTCTCCGAAACAAATGCCAAGTTGTTAGCTGTACTT
CTTGACTTTCAAAAAAATACATGCACTTGTTATAGCAGTAAAAAAAAAAAAA

gi|3946833|gb|AI297426.1|;

TTCAAGTTGTGATGATTCTGCCGTTGAGTGGCTACCGCCCTAGCCCCAGTTCCCGCTCCGATG
ATGTACACGCTGATGTCCTTCCGATCGGACGACGTTGCGACGGATTGACTCCAGCCTGCACAC
CTCAAACGGAATCGAGCAGGCCAGCGGTGATGCCATGGCAACATCCACGGCAACTCGGCTGGATC
TCACCCGAGGGCGAGCACGTTGAGGTAAGTACGTCGCAATGAAAACGGATAACCAGCCCTCGGGAGCCT
GGATCCCCACTCCTCCTCAATCCCAGAGGCCATGCCGCGCTGGCTGGAGTCTCACCCCC
AGCACCCGAGCACCCCGTCATCACTAGGACTCGTACCCGGATCCCGACCACTCCACGGACTGTTCTC
CCGAAACAAATGCCAAGTTGTTAGCTGTACTTCTTGACTTTCAAAAAAATACATGCACTTGCTTATA
GCAGTAAAAAAAAAAAAA

gi|3946548|gb|AI297141.1|;

TTCGTTCTCGACCAGACAGAAATCAGCCAACATGTTCAAGTTGTGATGATTCTGCCGTTGAGTGGAGT
GCTACCGCCCTAGCCCCAGTTCCCGCTCCGATGATGTACACGCTGATGTCCTTCCGATCGGACGACG
TTCGTGCCGACGGATTGACTCCAGCCTGCACACCTCAAACGGAATCGAGCAGGCCAGCGGTGATGC
CCATGGCAACATCCACGGCAACTCGGCTGGATCTCACCCGAGGGCGAGCACGTTGAGGTAAGTACGT
GCGAATGAAAACGGATAACCAGCCCTCGGGAGCCTGGATCCCCACTCCTCCTCAATCCCAGAGGCCATCG
CCCGCGCCGTTGCCCTGGAGTCTCACCCCCCAGCACCCGAGCACCCCGTCATCACTAGGACTCGT
ACCCGGATCCCGGACCACTCCACGGACTGTTCTCCGAAACAAATGCCAAGTTGTTAGCTGTACTTC
TTGACTTTCAAAAAAATACATGCACTTGTTATAGCAGTAAAAAAAA

gi|3945292|gb|AI295885.1|;

TTCGTTCTCGACCAGACAGAAATCAGCCAACATGTTCAAGTTGTGATGATTCTGCCGTTGAGTGGAGT
GCTACCGCCCTAGCCCCAGTTCCCGCTCCGATGATGTACACGCTGATGTCCTTCCGATCGGACGACG
TTCGTGCCGACGGATTGACTCCAGCCTGCACACCTCAAACGGAATCGAGCAGGCCAGCGGTGATGC
CCATGGCAACATCCACGGCAACTCGGCTGGATCTCACCCGAGGGCGAGCACGTTGAGGTAAGTACGT
GCGAATGAAAACGGATAACCAGCCCTCGGGAGCCTGGATCCCCACTCCTCCTCAATCCCAGAGGCCATCG
CCCGCGCCGTTGCCCTGGAGTCTCACCCCCCAGCACCCGAGCACCCCGTCATCACTAGGACTCGT
ACCCGGATCCCGGACCACTCCACGGACTGTTCTCCGAAACAAATGCCAAGTTGTTAGCTGTACTTC
TTGACTTTCAAAAAAATACATGCACTTGTTATAGCAGTAAAAAAAA

gi|3945124|gb|AI295717.1|;

TTCGTTCTCGACCAGACAGAAATCAGCCAACATGTTCAAGTTGTGATGATTCTGCCGTTGAGTGGAGT
GCTACCGCCCTAGCCCCAGTTCCCGCTCCGATGATGTACACGCTGATGTCCTTCCGATCGGACGACG
TTCGTGCCGACGGATTGACTCCAGCCTGCACACCTCAAACGGAATCGAGCAGGCCAGCGGTGATGC

```
CCATGGCAACATCCACGGCAACTTCGGCTGGATCTCACCGAGGGCGAGCACGTTGAGGTAAAGTACGTC
GCGAATGAAAACGGATACCAGCCTCGGGAGCCTGGATCCCCACTCCTCCTCCAATCCCAGAGGCCATCG
CCCGCGCCGTTGCCTGGCTGGAGTCTCACCCCCCAGCACCCGAGCACCCCCGTACACTAGGACTCGTC
ACCCGGATCCCGGACCCTCACGGACTGTTCTCCGAAACAAATGCCAAGTTGTTAGCTGTACTTC
TTGACTTCAAAAAAATACATGCACTGCTTATAGCAGTAAAAAAAAAAAAAA
```

gi|3866732|gb|AI259207.1|;

```
CCAACATGTTCAAGTTGTGATGATTCTGCCGTTGTGGAGTGGCTACCGCCCTAGCCCCAGTTCCCG
CTCCGATGATGTACACGCTGATGTCCTTCCGATCGGACGACGTTGCGCAGGGATTGACTCCAGC
CTGCACACCTCAAACGGAATCGAGCAGGCCAGCGGTGATGCCATGGCAACATCCACGGCAACTTCG
GCTGGATCTCACCGAGGGCGAGCACGTTGAGGTAAAGTACGTCGCAATGAAAACGGATAACCAGCCCTC
GGGAGCCTGGATCCCCACTCCTCCTCCAATCCCAGAGGCCATGCCCGCGCGTTGCCTGGCTGGAGTCT
CACCCCCCAGCACCGAGCACCCCCGTACACTAGGACTCGTCACCCGGATCCGGACCCTCACCGGA
CTGTTCTCCGAAACAAATGCCAAGTTGTTAGCTGTACTTCTGACTTCAAAAAAATACATGCACT
TGCTTATAGCAGTAAAAAAAAAAAAAA
```

gi|48956556|gb|CO183675.1|;

```
AGCCAACATGTTCAAGTTGTGATGATTCTGCCGTTGTGGAGTGGCTACCGCCCTAGCCCCAGTTCC
CGCTCCGATGATGTACACGCTGATGTCCTTCCGATCGGACGACGTTGCGCAGGGATTGACTCCA
GCCTGCACACCTCAAACGGAATCGAGCAGGCCAGCGGTGATGCCATGGCAACATCCACGGCAACTT
CGGCTGGATCTCACCGAGGGCGAGCACGTTGAGGTAAAGTACGTCGCAATGAAAACGGATAACCAGCC
TCGGGAGCCTGGATCCCCACTCCTCCTCCAATCCCAGAGGCCATGCCCGCGCGTTGCCTGGCTGGAGT
CTCACCCCCCAGCACCGAGCACCCCCGTACACTAGGACTCGTCACCCGGATCCGGACCCTCACCG
GACTGTTCTCCGAAACAAATGCCAAGTTGTTAGCTGTACTTCTGACTTCAAAAAAATACATGCA
CTTGCTTATAGCAGTNAAAAAAAAAAAAAAATATTAGGGCGGCCGCTAGAGGATCCA
AGCTTACGTACCGTGCATGCGACGTCATAGC
```

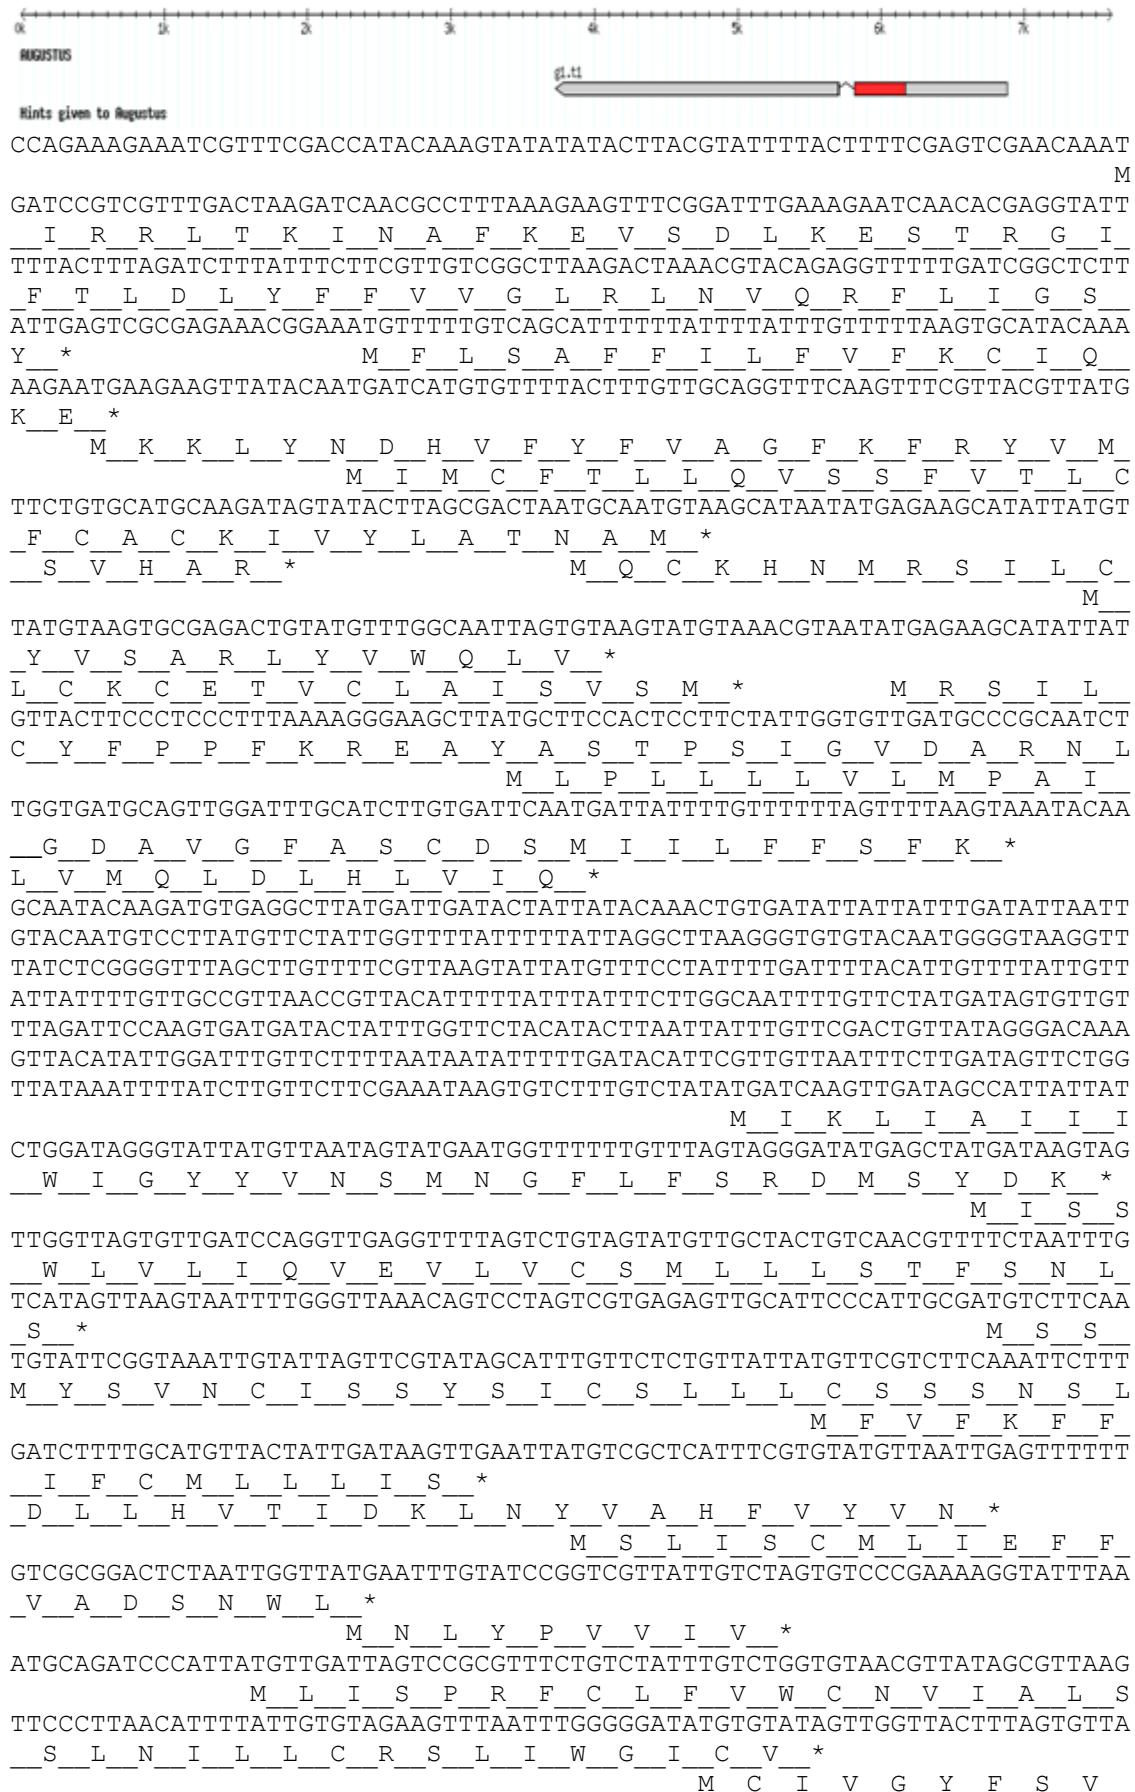
gi|49006763|gb|CO195588.1|

```
GAAATCAGCCAACATGTTCAAGTTGTGATGATTCTGCCGTTGTGGAGTGGCTACCGCCCTAGCCCCA
GTTTCCCGCTCCGATGATGTACACGCTGATGTCCTTCCGATCGGACGACGTTGCGCAGGGATTG
ACTCCAGCCTGCACACCTCAAACGGAATCGAGCAGGCCAGCGGTGATGCCATGGCAACATCCACGG
CAACTTCGGCTGGATCTCACCGAGGGCGAGCACGTTGAGGTAAAGTACGTCGCAATGAAAACGGATAC
CAGCCCTCGGGAGCCTGGATCCCCACTCCTCCTCCAATCCCAGAGGCCATGCCCGCGCGTTGCCTGGC
TGGAGTCTCACCCCCCAGCACCGAGCACCCCCGTACACTAGGACTCGTCACCCGGATCCGGACCAC
TCCACGGACTGTTCTCCGAAACAAATGCCAAGTTGTTAGCTGTACTTCTGACTTCAAAAAAATA
CATGCACTTGCTTATAGCAG
```

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 23 sORFs. Se pueden observar varias repeticiones. La transcripción se basa en la presencia de 10 ESTs en la base de datos pública y la probable traducción en la presencia en bases de datos de 2 péptidos definidos por espectrometría de masas que cumpliría con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación. Esto significa que al menos 2 de los sORFs codificados por este transcripto son traducidos.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_5



AAATAGTGAGTTAGGTTGTCTATATCCAAGAGGTTATCGGGAGACAGTGGTGGTCGATTCTGAAGGGAA
 K_I_V_S_* M_R_R_Q_W_C_S_Y_S_E_G_
 TTTGAATAGGTTGTCAGAGAATAGGAGATATCCGTGGTCGGTGCATGTTGTTATTGGAGTTGCTG
 I_* M_L_F_I_W_S_C_W
 GGCTTGGCATAGTTGTAAAGAGTAAGAAAAAGTATTATGGTGAACAAGGGGCCGTAAAATGGGAAGTT
 A_W_H_S_F_V_R_V_R_K_S_I_M_V_N_K_G_P_V_K_W_E_V
 GATTAGTTCTCTGTTAAATTGGTCTTAGTAATGTTGCTCTGTTCTGTTAGTAATT
 D_* M_C_L_S_V_S_V_S_N_F
 GTAATGGCTTCGTCGGTTGTCGACAGTTCTAGTAATTGAAAGGGCTCTAATTTCCTTTGT
 V_M_V_F_V_G_L_F_D_V_L_C_*
 ATGGTCCTTCTGTATCTGGAGTCGACATTATTCAGTTCTATTCTATTTCGTTAATT
 M_V_L_F_C_I_W_S_R_H_Y_I_Q_F_Y_S_Y_L_F_R_*
 TTTCTTATTGTTGTTGTTCTAAGTTAGGTTGTCGGCGTAAATGAATATGTGAGCAGGGGTTGTC
 GGTAGTATCGTGGTTGTTGTTGTTAAATGTAAGGATTGTTCTATTACTTAATTGGTCTCG
 TTGTCGTCAAGAGTTTTATGATGCGGATTTTCGTTATAGTTGAGTCTCTATGTCAGCGA
 CACCTGTTTGTAGTATTAAGTGTAACTCTACTTCGGTTCGAGCCAACGTTGAGGGCTAGGCT
 GGAGAATGCACCATCTCGATCTGCTTGAGAAGTTAGGTTCCCTAATTGATTAATGCACATTAAG
 M_H_I_K
 GCATTTGCATTCTACCCAGTCTTGTCTTAATCTGTTCAAGGGTGGCGAATTAGAGTAAATATCGA
 A_F_L_H_S_T_Q_S_F_V_L_I_C_S_R_V_A_N_L_E_*
 TACAGCTCAGATAATGGTTCCCTCGGAAGAATAGATGCTATTACGAACTTACGACAATGTTGG
 M_V_S_F_G_R_I_D_V_Y_Y_E_L_I_T_T_M_F_G_
 M_S_I_T_N_L_S_R_Q_C_S_G
 TTTAGGGTAATTTCATTGGCATTCCGTGTTACGGTGTCTGTTGGTAGGTTGCAGACTGACAT
 F_R_G_N_F_H_W_H_F_R_V_T_V_F_C_F_G_*
 L_G_V_I_F_I_G_I_S_V_L_R_C_S_V_L_A_R_L_Q_T_*
 TCGTTGATTATATTCTGGATAAGGAGTTGGCTATTGGGAAGTAATAATTCTCACTAAAGAGTTTACAG
 TTTTGAAATTCCGGGGTGTCTTAAACTGCATAAGTAGGGATGTTTTAATAAACGAGGCTTCG
 M_F_F_N_K_T_R_L_R
 GAAAATTTCGATTTCGGATTCTGGTGTATATGCATTGGATCATTGCAAGTCTGCATCG
 K_I_F_V_H_F_G_F_I_V_V_V_Y_A_F_W_I_I_S_K_S_A_S_
 M_H_F_G_S_F_R_S_L_H_R
 CTTTCGATGTAAGAGCGCTATTCTTGAGCAAAGTGATTGAGTAGATATTGTTGGCTGCTTAGGG
 L_S_M_*
 F_R_C_K_E_R_Y_S_L_S_K_S_D_*
 TCATTTCTTGAGGAAATGTTGATGATTGTTGGAAATAAGTTGTTCTATACTACTATTGGG
 ACCTTTGAGAAATAATTGTCTTTATGTAATTATGGCTTTCCGACAACCCATTAGTCGCTA
 M_V_I_N_G_F_F_G_Q_P_Y_*
 TTATCTTCTCGCGCTATGTTGCGTAGATTCTCCGAAAATGCTGTTCTATTGATTCTAGACAGTG
 M_L_R_R_F_S_E_K_C_L_F_Y_F_D_S_R_Q_C
 CGTCTCGACATGGTTCCCTTGTATATTATCGAAGTCGTAUTGGATAATCTAATCTT
 V_C_D_M_V_F_L_S_F_D_I_F_Y_I_E_V_V_L_G_*
 CCACCTAGTCAGCTTGAGTTAGGTTCTTAAATTGTTGAGCCAACACAATGGTGATGGTCAGAAGCT
 M_V_D_G_Q_K_L
 M_V_R_S
 ATTTCGAAATGTCGCTAACAGGTAGTGTCTAAAGGTCTTGTGGCCAAACTATTGCTAGTTCTT
 F_R_N_V_V_L_T_G_S_V_*
 Y_F_E_M_S_S_*
 TTTCTATAGCACTGTAATTAACTTCATGTTGTTAGGGCTCTGTAATGTTAGCTAATGGGATGTCCATC
 TTGAGATAGAACAGCACCTAATGCTACATTGCTTGCAGTTGTTAATACAAATTCTTCAAAATT
 M_L_H_C_L_R_Q_L_L_I_Q_I_F_F_Q_N_*
 GGTATTTAATATGGGTCTCGGAAATAAGTAATTGAAATGCTTATATTCTATATTCTTAT
 M_G_S_S_E_I_S_N_F_N_F_* M_L_L_Y_I_L_Y
 GTTTGTATCTATTGTTACTCCCTTTGAGACATTAGTCAGTGGTTCGCTATGTCAGAGAAGTTGG
 V_L_Y_L_F_L_L_P_F_* M_S_E_K_L_G
 TATGAATTCCCTGTAGTATCCTGATTCCAAGGAATGCTTAATTCTTAGGTTAGATGGAAGTGG
 M_N_F_L_*
 TAATCTTGATAGCTTGATTGTTGGGATTGGTTAATTCCGTCTTAGTGTAGTAAAGGTTGGCTGAGATAATTCTCG
 GGTAGTTCTGTCTAGGAATTACACATTATCTAGCTGTAGTTAAGGTTGGCTGAGATAATTCTCG
 AAGACTGCTTCAAGGGATTGAAGGTGTTCCCTAGAGAGGTAGAAAAGACAATGATATCGTAGATATA

M_I_S_S_R_Y
CTAAACAATTTATTTAAAAGTGGACGAAGTAGGTTATTGCAGCGTTGGAAGGTAGCTGGGCGTT
T_K_Q_F_L_F_K_S_G_R_S_R_L_F_M_Q_R_W_K_V_A_G_A_F
TTAAGCCCAAATGGCATTCTAGTATTCGTAATGTCCGTATTAGAGAAAGCCGTTGGCTATT
L_S_P_N_G_I_L_V_Y_S_* M_S_V_F_S_R_E_S_R_F_G_Y
GATTCTGAATCCATCTCTATTGATGGAAGCCTTTGCCAGGTCTATGGTGGTAAAGTAATTAGACCTCC
* M_E_A_F_C_Q_V_Y_G_G_K_V_I_R_P_P
CTAACTTCCTAATATTCGTCTATTTGGCATAGGGTATCGGTATTGTTATTCAACTT
*
CCTGTAGTCTATGACTATTCGAAGTTCTGCTGTCGGAAAGCATCTAATTTGGTACTACCCAGATG
M_T_I_R_S_F_C_C_P_E_A_S_N_F_F_G_T_T_Q_M
GGGCTGCAGTACGGTGAGTTGCTTCTGAATGATGCCCTGTTCTAACATTTCTTGAATTGTC
G_L_Q_Y_G_E_L_L_S_R_M_M_P_C_S_N_I_S_*
CTTCTGTTCGTATGATTGGAAGCTATACATTAGAGTAAACTGGAATATTATGTGTGGTATTAAAT
M_C_G_I_N
TGTATGTTTCTGGTTGAGCTAAGTTGTCGCCCTCGTGAAGACTGAATGTC
C_M_F_F_L_V_C_E_A_K_F_V_A_L_V_K_L_N_V_F_E_S_C
M_S_L_N_L_V
AGTAAGTTGTTAATTGTATTTCTGCATTAAATGGTTAGTCGGAACAGATTCTCCTGAAGTG
Q_*
S_K_F_V_N_L_Y_F_S_S_A_F_K_W_F_S_R_N_R_F_S_*
TGGAGGTTCTAAAAGGTAGGGCTTGTGGAACAGAAGAGTCTACTGAGCATGATTGTC
M_I_L_V_C_K
TTTTCACTGTCTTTATTTAGACTTGTGAAGAGGGTGGCAGTTCTTGTATAATCTATTATG
F_F_S_V_F_Y_F_I_D_F_V_E_E_G_G_S_F_L_L_I_I_Y_Y
M
GCTTAGCTTAGACAACAATTGCGTCCAATCAGCATATCATAATGATCTGAGAATTGTGAATTAGAA
G_F_S_F_R_Q_Q_F_A_S_N_Q_H_I_I_M_I_*
A_L_A_L_D_N_N_L_R_P_I_S_I_S_*
ACTCCTGAGCAATAGGAAAGTAGTTATTGGGTGGTATAGTGGTGGTCTCGTAATAGTTAACAGCCATT
ACTTGTATGAATTAGGTGGTTGGTTGTATAGGTGTTCGAAATGTTCAAGTAAGCATGTTATG
GTGGATCCAGTGTCAATTAGGCACCTTAAGTCTATGTCATTGTTAATAATTACATATTGGTTGATC
CGGGGCAACTAGCCAAAATTCTGCTCTTGGTATTGTCGATTCGTATCGTTGGTGTCTGT
TCTTGTGTTGTCCGAAGTGTATGATCTGTTGAGAGGGATTAAAGTGGGTCTGGGATATAAC
M_I_L_F_E_R_D_L_S_W_V_W_D_I_T
CCATTGATAAGGATATGGTTGTTGGAAGTTATCTGGTAGTATGGATAGTAATAATGGTAAGGGTA
H_L_I_R_I_W_L_W_L_E_V_I_W_V_V_W_I_V_I_M_V_R_V
TTCGGGTTGGTTGATACCATTCTGGTATCTAGTTCTTCTATGCTCATTAGTCTGTC
F_G_L_V_* M_L_I_L_V_C_P_L_S
GATGGTCGTTGTCTTTACCGGGTTGGTTGTGTTCCCAGTTGGAGGGAAAGTTACCGGTGT
D_G_R_C_L_F_T_G_L_L_V_C_V_F_P_V_G_G_K_L_F_G_V
M_V_V_F_L_P_G_C_W_F_V_C_S_Q_L_E_G_S_Y_S_V_C
AAGTTGATTAGTCCGAAACGATTGGTCGAAGATATTCTGTCGATTAAGACAGGATTGGGTCTGGG
*
K_F_D_*
TATGTTAGGTTGTGGGTAGGTTGGTCTTGGTTGATATTGGGAAAAGGGGTTGATTGGACCTGGGTGTA
TGGATTGGTGCCTATGGGTATGGTGGATAATAGGGTTGAAAGACGTTGTTATGGTACGGTTGAAAGGTG
M_D_W_C_V_W_V_W_W_I_I_G_L_K_D_V_V_M_V_R_L_K_R_C
M_G_M_V_D_N_R_V_E_R_R_C_Y_G_T_V_E_K_V
TTATAGGTTATTTGGCCATTAACTGTCTATTGGTAAGTTACTTGGCGTCCTATTAGAATTAGGAGC
Y_R_F_I_L_A_I_N_L_S_I_W_*
L_*
TGGCTAAAGTTATTTGTTAATGTTGAGGTTCATATAGACCCTTCTGTAAGATATTAAAGG
M_F_E_V_H_I_D_P_F_L_V_R_Y_*
GATCTAAATCGGAATTGGCAGTTAACTATTCTAGTGAATATGGTAGGGAGTTAGGATCAAGT
TTCTATGCTATCTGAATAAGTCTGGTAAATAAGGCCTTCAGCTGAGTTATTCTAGTCTAACTT
ACTCATTAAAACCTGTCGTTCTCGGCTCCTCCAGAAACTGCCTGATGTTGCCATTGTATTGAATG
TTCCGAAAATCCTCCAAAAGTTGATGACTCGGTGCTGGGGTTGTAATATAGGATCAATCTGGCCTTA
M_T_R_C_L_G_F_V_I_*
GTTCAATCCAGCTGGTGAAGTTGGTCCCGAGAGTACGGATGACGTCGCCGCTGATATTGCGTTCAAT
M_T_S_P_L_I_L_R_S_M

GTGTCCATAAATTATCAACTTCTGCCTTCGTCAGTAGTTGGTATAAGGCCAGAACATGAAGTCGATGCAG
 C_P_*
 GTTATAAAGGTATGTAGAGTATTGGGCTCCATTGAAGATTGACAGCATTATCTGTCTCGACCT
 V_I_K_V_C_R_V_F_G_S_P_L_K_I_S_T_A_F_I_C_L_S_T
 GACTCATATTGAGTCGGATAGTATTAGGGCTGCTGGCATTGGTGTGTTATTTATTGTTAT
 TTAATGTTAGGTAAGGTTACGTTCTGGGTAAGGCTGAGTCGGATAGGTTCGTTTCGATAA
 GGTTCAAGTTTACTGTAGGTTTGCTCTGGTCAACTTAGGTTATGTTGGATAGGGTTGG
 * M_F_W_I_G_F_W
 TTTTCACTATGGGTCTTGATTTCACTATTGGTTGTATTCCAGGTCTGAGCTTGTGTTGTGTTGT
 F_S_L_W_V_L_D_F_H_Y_W_F_V_F_Q_V_*
 TGTTGTTCACTTATTAATTCACTTATAATGTTGTTATTCACTTAGTTATAGTTCTTAGCTTA
 M_F_V_I_H_L_V_I_V_L_*
 GGTTTGTGAATTTCGCACTTATTGTTGTAATATTCTGTTATTCACTTATTGTAAGTTTTAAT
 TTAAGTTGTTGTTGCGCTCTAGCTGTTGCTTGGTTGAGTAACCTTTGTGGATTACTACTC
 AGCGAATTCAAAGGCCTTCTTAAATTTTTGTAATTAAAGTTATTCACTTCGTGGTCACTTAT
 GGGATTGAGTACCACTGGTTAACACTTCCGCGGTAACTGACACGATCCGCGTTGTTAT
 AAGGTTAGTTACCGTTGGTAGCACTTCCACTAGCACGACGCGACTGCGTTAGTTCTTGTTGAT
 AATAATTGAAGAATTGAATAGGGTTACTATCGCATCAACAATGTATTACCTACCGACTGCCACTTAC
 M_Y_Y_P_T_D_C_A_T_Y
 TGATTTACTTTCGAGTCGAACAAATGATCTGCGTTGACTAAGATCAACGCCCTAAAGAAGTTCG
 V_F_Y_F_S_S_R_T_N_D_L_S_F_D_*
 M_I_C_R_L_T_K_I_N_A_F_K_E_V_S
 GATTGAAAGAATCAACACGAGGTATTTACTTAGATCTTATTCTCGTGTGCGCTTAAGACTAA
 D_L_K_E_S_T_R_G_I_F_T_L_D_L_Y_F_F_V_V_G_L_R_L
 ACGTACAGAGGTTTGATGGCTTATTGAGTCGGAGAACGGAAATGTTTGTCAGCATTTTA
 N_V_Q_R_F_L_I_G_S_Y_* M_F_L_S_A_F_F
 TTTTATTGTTTTAAGTCATACAAAAGAATGAAGAAGTTACAAATGATCATGTGTTTACTTGTT
 I_L_F_V_F_K_C_I_Q_K_E_*
 M_K_K_L_Y_N_D_H_V_F_Y_F_V
 M_I_M_C_F_T_L_L
 GCAGGTTCAAGTTGTTACGTTATGTTCTGTCATGCAAGATAGTATACTTAGCGACTAATGCAATGT
 A_G_F_K_F_R_Y_V_M_F_C_A_C_K_I_V_Y_L_A_T_N_A_M
 Q_V_S_S_F_V_T_L_C_S_V_H_A_R_* M_Q_C
 AAGCATATGAGAAGCATATTGTTATGTAAGTGCAGACTGTATGTTGGCAATTAGTGTAAGTAT
 *
 K_H_N_M_R_S_I_L_C_Y_V_S_A_R_L_Y_V_W_Q_L_V_*
 M_L_C_K_C_E_T_V_C_L_A_I_S_V_S_M
 GTAAACGTAATATGAGAAGCATATTGTTACTATATTCTGATCAGAGAACAGAGAAATATAAGGTA
 * M_R_S_I_L_C_Y_Y_I_F_L_I_R_E_Q_R_N_I_R_*
 M_L_L_Y_I_L_D_Q_R_T_E_K_Y_K_V
 ACAAATAATCCGAGGGCGAACAAACACTTGTACACGACTGTGACCAGATCTAGCCTGACACAAGG
 T_N_K_S_E_G_E_Q_T_L_C_H_T_T_V_T_R_S_I_A_*
 AACCGATGCCCTAGAGAACATGAACGACCAACCGACCACATCCAGATGAAACAGTTAAACTCAGTAGAA
 M_N_D_Q_P_T_T_S_R_*
 M_K_Q_L_N_S_V_E
 AACAAAGAGAGAATGCTATAGTCAGATCCCCACTATCAGATACCCG
 N_K_R_E_C_Y_S_Q_D_P_H_Y_Q_I_P_G_*

Para la región genómica 2R_5, el programa Augustus Gene Prediction predijo una estructura compuesta por 2 exones de 1972 pares de bases el primero, y 1062 pares de bases el segundo, y 1 intrón de 110 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido SLNLVSK con una probabilidad de $p=0.002$ y un valor E=0.000113327640664902; para el péptido GIFTLDLYFFVVGRLNVQR con una probabilidad de $p=0.078$ y un valor E=3.79387154351475e-05; para el péptido SITNLSR con una probabilidad de $p=0.004$ y un valor E=0.000894416822897423; para el péptido MIMCFLLQVSSFVTLCVHAR con una probabilidad de $p=0.035$ y un valor E=0.000351924336191395; para el péptido IMCFLLQVSSFVTLCVHAR con una

probabilidad de $p=0.029$ y un valor $E=0.000732423818564053$; para el péptido LISPRFCLFVWCNVIALSSLNILLCR con una probabilidad de $p=0.033$ y un valor $E=0.000363678919483202$; para el péptido ERYSLSK con una probabilidad de $p=0.064$ y un valor $E=0.0001266509436431$; para el péptido VDGQkLFR con una probabilidad de $p=0.016$ y un valor $E=0.00016400775031939$; para el péptido ME AFCQVYGGK con una probabilidad de $p=0.038$ y un valor $E=0.000943166356804488$.

Evidencia de ESTs:

gi|49216375|gb|CO294829.1|;

GAGATAAACCTTACCCATTGTACACACCCTAACGCTAATAAAAATAAAACCAATAGAACATAAGGACA
TTGTACAATTAAATCAAATAATAATCACAGTTGTATAATAGTATCAATCATAAGCCTCACATCTG
TATTGCTGTATTACTTAAACTAAAAACAAAAATAATCATTGAATCACAAGATGCAAATCCAACACTGC
ATCACCAAGATTGCGGGCATCAACACCAATAGAAGGAGTGGAAAGCATAAGCTCCCTTTAAAGGGAGGG
AAGTAACATAATATGCTCTCATATTACGTTACATACTTACACTAATTGTACATACAATCTGCACATG
CATAAACACATGAAACCAGTTACATTTTACTTACACTTAAGCGCATAATTGTTGTGCATCCATACCG
TTATTTTCCGTTCTTTTGACACATATACTGATTAGACATTCCGTTCTCGCGACTCACTCGAGC
CGATCAAAAACCTGTACAGTCAGTCTTAAGCCGA

gi|49401009|gb|CO340714.1|;

TCGGCTTAAGACTGACTGTACAGAGTTTGATCGGCTCGAAGTGAGTCGCGAGAACGGGAATGTCTAA
TCAGTATATGTGTACAAAAAGAACGGAAAATAACGGTATGGATGCACAACAAATTATGCGCTTAAGTG
TAAGTAAAATGTAAACTGGTTCATGTGTTATGCATGTGCAAGATTGTATGTACAATTAGTGTAAAGTA
TGTAAACGTAAATATGAGAACGATATTATGTTACTTCCCTCCCTTAAAGGGAGCTTATGCTTCACTC
CTTCTATTGGTGTGATGCCGCAATCTGGTATGCAGTTGGATTGCATCTTGATTCAATGATTAT
TTGTTTTAGTTAAGTAAATACAAGCAATACAAGATGTGAGGCTATGATTGATACTATTATAACAA
ACTGTGATATTATTATTGATATTAAATTGTACAATGCTTATGTTCTATTGGTTTATTGTTATTAGGC
T

gi|103678882|gb|EC060256.1|;

AAGTTTTAATTAAAGTTGTTGTTGTTCACTTATTAAATTAAATTCACTTATAATGTTGTTATTCA
TTAGTTATAGTCTTAGCTTAGGTTGTTGAATTTCGCACTTATTGTTGTAATATTCTGTTATT
CACTTATTGTAAGTTTAATTAAAGTTGGTGGGTTGCGCTCTAGCTGTTGCTTGTTGAGT
AACCTTTGTTGATTTACTACTCAGCGAATTCAAAGCGTCTTCTAAATTTGTAATTAAAGTTAT
TTCACTTCGTTGACTTTATGGGATTGAGTACCATGGTTAACACTTCCACTT

gi|107316563|gb|EC259523.1|;

ATCCATACCGTTATTTCTGTTCTTTGTACACATATACTGATTAGACATTCCGTTCTCGCGACT
CACTTCGAGCCGATAAAAACTCTGTACAGTCAGTCTTAAGCGACAACGAAGAACATAAGATCTAAACT
AAAAAAATACCTCGTGTGATTCTGAAACTTCTTAAAGGCCTGATCTAGTCAAACGACGGATCATTG
TTCGACTCGAATAGTAAACGTAAGTGGCGCAGTCGGTAGGATAATACATTGTTGATGCGATAGTAAC
CCTATTCAATTCTCAATTATTATCCACAAAAGAACTAACGCACTCGCCTGCTAAGTGGAAAGTGT
AACCAATGGTACTCAATCCCATAAAGTGACCACGAAGTGAATAACTTAAATTACAAAAAT

gi|49403391|gb|CO343084.1|

GCATCCATACCGTTATTTCTGTTCTTTGTACACATATACTGATTAGACATTCCGTTCTCGCGA
CTCACTTCGAGCCGATAAAAACTCTGTACAGTCAGTCTTAAGCGACAACGAAGAACATAAGATCTAA
CTAAAAAAATACCTCGTGTGATTCTGAAACTTCTTAAAGGCCTGATCTAGTCAAACGACGGATCATT
TGTTCGACTCGAATAGTAAACGTAAGTGGCGCAGTCGGTAGGATAATACATTGTTGATGCGATAGTA
ACCCTATTCAATTCTCAATTATTATCCACAAAAGAACTAACGCACTCGCCTGCTAAGTGGAAAGTGT
TTAACCAATGGTACTCAATCCCATAAAGTGACCACGAAGTGAATAACTTAAATTACAAAAAT

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 63 sORFs. La transcripción se basa en la presencia de 5 ESTs en la base de datos pública y la probable traducción en la presencia

en bases de datos de 9 péptidos definidos por espectrometría de masas que cumpliría con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación. Esto significa que al menos 9 de los sORFs codificados por este transcripto son traducidos.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_35



```

GAACTAACAGCTCTCCCACATTGCAGCCTTTATATCCGCCTGTTGTGAAATCGAACTTCGAAAAAGC
TTGAGGCATTGGGAGAGCCAATAAGAGAGGAAGGTCTATGTTTGGTATTATTGCTCAGAGTGAATC
M_F_L_V_L_L_L_R_V_N_
ATCACGAAACGGTGGCGCCACCTTCAGGGCGTCGAAATCCTCTGAAAAGGATCTAAGTGGGCATT
H_H_E_T_G_G_A_H_L_Q_G_R_R_N_P_P_A_K_G_S_K_W_A_F
CACCGGGCGGGGGTTTTGCTAGCTCACAAAGGACCAGGATCAGACGAAAATCAGCAAATATATGG
T_G_R_G_V_F_C_*_M_
TTACAATAGCGATGATTGCCATGTCCTCAACACAGTGATCATATCTTTGATAGCAAATAATCGCTT
V_T_I_A_M_I_A_M_S_L_N_T_V_I_I_S_F_D_S_Q_I_I_A_F
TTCTCCGCTGACCGGCACAAAGTGGAGCCGGCGGTGAGAATCAACGGTTGTGCGGGCGGCTGGAGA
S_P_L_T_G_T_K_W_S_R_R_L_*_M_
TCAGGCAACATCCATTCAGACTCGCAATGTCAAAACATAAGATTGAGAAAATGGAGCTCCATGCCGA
M_E_L_H_A_E
GGCACTTCACCCGCCATTGGTTGAATATCATATTCCCATTCGAATAACCGATCTACGGACGAAA
A_L_H_P_P_F_G_S_N_I_I_F_L_H_C_E_*_M_
TGCCAGATCCTCAGCCGCCCGCCGATGATTCTGAAATCTAGTTCTAGTTGCAAATAAGGTTCAAT
M_P_D_P_Q_P_P_R_P_M_I_L_E_I_*_M_
GTTGCAATAAAATTATTGCTTCCAAAAGCTGGCGTCTGTGCCAAAGTAGCCGCAAGTCGGCGTGAAA
TTATATGAAAATAGAGCCGTTTCAGGGCATTGCCAATAGCAATAACACAGCGTGGATTGTGGATTTC
M_K_I_E_P_F_S_R_H_C_E_*_M_
AGAAGCTAGTCGAGGCTTACCGCACGCCATTGCCAGTGAGTATGAAGAGTATGAAGAGATGTGGCTGC
M_K_S_M_K_R_C_G_C_*_M_W_L_
TGTGCTGCTGTTGATGTGGCTGCTCCCCATCTCAGCTCTGGTTGGCTCTGACGTCGAT
C_C_C_C_C_*_M_
L_L_L_L_L_M_W_L_L_P_I_S_S_S_P_V_V_G_L_S_L_T_S_I
CGGCTGGCGAGGCTACGAAAAGTTCTGTTGGTGGCGGCAGCAGCGATGAGGTCTCAATGACGTTGG
G_W_R_G_Y_E_K_F_C_L_G_G_R_Q_Q_R_*_M_
CTGCTGCCTGTTGGTATTGATGTTCTTGTGCCACTCCTCGTGTGCTGCCCTGCGATCCTTC
TGGCGCTTACGGCAGTTGTCGAAGGTGTGCCCGGAACTGCAGTAGGTGCAGCGGGTGGTGCCTTGG
AGCCACGGGTGT

```

Para la región genómica 2R_35, el programa Augustus Gene Prediction predijo una estructura compuesta por 1 exón de 1082 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido
VNHETGGAHLQRR con una probabilidad de $p=0.097$ y un valor
 $E=0.000424343980856626$.

Evidencia de ESTs:

gi|13696898|gb|BF502961.2|;

```

CTCCGCTTGCACACACAGCTTCGGCGGAACCCGGGACCACGACGTGGTCGAGGAGTTCATCGCAACATC
GAGACATACAAGGATGTAGAGGGTATCAGCAGAGAACGCCCTGAAGGGCATCTCGCTGTTCTACG
GTATGGCAGCACCTGGTGGCAAGCGTTCGCAAGGAGGCCACCACGTGGAAGGAAGCCATCGCTCTCAT
CCCGAACACTTCTGCCACCAAGCTCGCCTACCAGATCTACATGGAATTCTCCAAAACAAGCAGGAC
GACCATGACCCATTGACACCTTCGTATCCAGAAGCGAGCGCTGCTGCCAGCTGCCAGCGGTGCC
ACGACGAGGAAACGGAACTGGATCTTCTGGTCTGCTGAACATCAAGTACCGCAAGCACATCTCCG
CCACAGTGTCCATACCTCAAGGATCTCTGGAACAGGGCCATCATCGAGCACAAACACCAGGAGGAC
GAGGAACAGCTTGCACAGCAAAGAACACCCGTGGCTCAAGCGCACCACCGCTGCACCTACTGCAGTT
TCCGGNGGCACACCTTCGACAACGCTGCCAGCGAGAAGGATCGGCAGGAGGAGCAGCACGAGGAGTA
GGCGACAAAAAGAACATCAAATACCAACAGGCAGCAGCCAACGTCATTGATGACCTCATCGCTGCTGCC
NCCACCCAAACAGAACCTTCCGGAGCCTGCCAGCGATCGACGTAGAGAGGCCAACACCCGGAGAG
CTGA

```

gi|13756611|gb|BF490911.2|;

```

CTGAACCAAGATTAATTGATCACCTAACCTCACACAGCAGCGAAATGGCCAGCTTACACAGATGACC
AACGAGCAGCTCCGCGAGCTGATCGAAGAGCAGGCCGTGGCGCCGGAAAGTGCAGCAG
CAGCGGAGGAGCAGGCCAGCAGAGGCCAAAGGCAACTTCTCCGTTGCACACACAGCTTCCGGCGAAC

```

CCGGGACCACGACGTGGTCGAGGAGTTCATGGCAACATCGAGACATAAGGATGTAGAGGGTATCAGC
GACGAGAACGCCCTGAAGGGCATCTCGCTGTTACGGTATGCCAGCACCTGGTGGCAAGGCCTTC
GCAAGGAGGCCACCACGTGGAAGGAAGCCATCGCTCATCCGAAACACTTCTGCCAACAGCTCG
CTACCAGATCTACATGAAATTCTCCAAAACAAGCAGGACGACCATGACCCATTGACACCTCGTCATC
CAGAAGCGAGCGCTGCTGGCCAGCTGCCAGCGGTGCCACGACGAGGAAACGGAACGGAACTGGATCTTCTGT
TCGGTCTGCTGAACATCAAGTACCGCAAGCACATCTCCGCCACAGTGCCATACCTCAAGGATCTCCT
GGAACAGGGCCGCGATCATCGAGCACATCAACCAGGAGGACGAGGAACAGCTTGCCACAGCAAAGAACACC
CGTGGCTCCAAGCGCACCACCGCTGCACCTACT

gi|26255784|gb|CA806835.1|;

GCGTGGGCGCCGCCGGAAAGTGCAGCAGCAGGCCAGGAGCAGACGCCAGCAGAGGAAAGGAAACTTCTC
CGCTTGACACACAGCTCGCGGAACCCGGGACCACGACGTGGTCAGGGAGTTCATGGCAACATCGAG
ACATACATGATGTAGAGGGTATCAGCGAGAACGCCCTGAAGGGCATCTCGCTGCTGTTACGGTAT
GGCCAGCACCTGGTGGCAAGGCCTCGCAAGGGGCCACCACGTGGAAGGAAGCCATCGCTCATCCGC
GAACACTTCTGCCAACCAAGCCGCCTACCAGATCTACATGAAATTCTCCAAAACAAGCAGGACGACC
ATGACCCATTGACACCTCGTCATCCAGAAGCGAGCGCTGCTGCCAGCTGCCAGCGGTGCCACGA
CGAGGAAACGGAACGGATCTCTGGTGAACATCAAGTACCGCAAGCACATCTCCGCCAC
AGTGTCCATACCTCAAGGATCTCCTGGAACAGGGCCGATCATCGAGCACAAACCAGGAGGACGAGG
AACAGCTGCCACAGCAAAGAACACCCGTGGCTCCAAGCGCACCACCCGCTGCACCTACTGTAGTTCCG
GGGGCACACCTTCGACAACGCCGTAAGGCCAGAAGGATCGGCAGGAGGACGACGAGGAGTAGGCG
ACAAAAAGAACATCAAATACCAACAGGCAG

gi|13696731|gb|BF502793.2|;

CTGGCTTGTCCGCCACTGAACCAAAGATTAATTGATCACCTAACCTCACACAGCAGCGAAAATGGCCC
AGCTTACACAGATGACCAACGAGCAGCTCCCGAGCTGATCGAAGCTGTAAGAGCGGCCGCCGTGGCGC
CGCCGGAAGTGCAGCAGCAGGCCAGGAGCAGACGCCAGCAGAGGAAAGGAAACTTCTCGCTTGACAC
CACAGCTCGCGGAACCCGGACCACGACGTGGTCAGGGAGTTCATCGCAACATCGAGACATACAAGG
ATGTAGAGGGTATCAGCGAGAACGCCCTGAAGGGCATCTCGCTGCTGTTACGGTATGCCAGCAC
CTGGTGGCAAGGCCTCGCAAGGGGCCACCACGTGGAAGGAAGCCATCGCTCATCCGCAACACTTC
TCGCCACCAAGCCGCCTACCAGATCTACATGAAATTCTCCAAAACAAGCAGGACGACATGACCCCA
TTGACACCTCGTCATCCAGAAGCGAGCGCTGCTGCCAGCTGCCAGCGGTGCCACGAGGAAAC
GGAACGGATCTCTGGTCTGTTGAACATCAAGTACCGCAAGCACATCNCCGCCACAGTGTCCAT
ACCTCAAGGATCTCCTGGAACAGGGCCGATCATCGAGCACAAACAACCAGGAGGACGAGGAACAGCTTG
CCACAGCAAAGAACACCCGTG

gi|26255761|gb|CA806812.1|;

GCGTGGGCGCCGCCGGAAAGTGCAGCAGCAGGCCAGGAGCAGACGCCAGCAGAGGAAAGGAAACTTCTC
GCTTGACACACAGCTCGCGGAACCCGGGACCACGACGTGGTCAGGGAGTTCATGGCAACATCGAGA
CATACAAGGATGTAGAGGGTATCAGCGAGAACGCCCTGAAGGGCATCTCGCTGCTGTTACGGTAT
GGCCAGCACCTGGTGGCAAGGCCTCGCAAGGGGCCACCACGTGGAAGGAAGCCATCGCTCATCCGC
GAACACTTCTGCCAACCAAGCCGCCTACCAGATCTACATGAAATTCTCCAAAACAAGCAGGACGACC
ATGACCCATTGACACCTCGTCATCCAGAAGCGAGCGCTGCTGCCAGCTGCCAGCGGTGCCACGA
CGAGGAAACGGAACGGATCTCTGGTCTGTTGAACATCAAGTACCGCAAGCACATCTCCGCCAC
AGTGTCCATACCTCAAGGATCTCCTGGAACAGGGCCGATCATCGAGCACAAACAACCAGGAGGACGAGG
AACAGCTGCCACAGCAAAGAACACCCGTGGCTCCAAGCGCACCACCCGCTGCACCTACTGTAGTTCCG
GGGGCACACCTTCGACAACGCCGTAAGGCCAGAAGGATCGGCAGGAGGACGACGAGGAGTAGGCG
ACAAAAAGAACAT

gi|13687890|gb|BF505287.2|;

CTCCGCTTGCACACACAGCTCGCGGAACCCGGGACCACGACGTGGTCAGGGAGTTCATGGCAACATC
GAGACATACAAGGATGTAGAGGGTATCAGCGAGAACGCCCTGAAGGGCATCTCGCTGCTGTTCTACG
GTATGGCAGCACCTGGTGGCAAGGCCTCGCAAGGGAGGCCACCACGTGGAAGGAAGCCATCGCTCTCAT
CCGCGAACACTCTCGCCACCAAGCTCGCTACCAGATCTACATGAAATTCTCCAAAACAAGCAGGAC
GACCATGACCCATTGACACCTCGTCATCCAGAAGCGAGCGCTGCTGCCAGCTGCCAGCGGTGCC
ACGACGAGGAAACGGAACGGATCTCTGGTCTGCTGTAACATCAAGTACCGCAAGCACATCTCCCG
CCACAGTGTCCATACCTCAAGGATCTCTGGAACAGGGCCGATCATCGAGCACAAACCAGGAGGAC
GAGGAACAGCTGCCACAGCAAAGAACACCCGTGGCTCCAAGCGCACCACCGCTGCACCTACTGCAGTT
TCCGGGGCACACCTTCGACAACGCCGTAAGGCCAGAAGGATCGGCAGGAGGACGACGAGGAGTA
GGCAGACAAAAAGAACATCAAATACCAACAGGCAGCAGCCAACGTCATTGATGACCTCATCGCTGCTG

gi|15454856|gb|BI565664.1|;

GTCAGTTCAAATCACGGCCGCATTGCTACACTGGTTGTCCGCCGACTGAACCAAGATTAATTGAT
CACCTAACCTCACACAGCAGCGAAATGGCCAGCTTACACAGATGACCAACGAGCAGCTCCGCGAGCTG
ATCGAAGCTGTAAGAGCGGCCGCGTGGCGCCGCCGGAAAGTGCAGCAGCAGCCGGAGGAGCAGACGCCA
GCAGAGGCAAAGGCAACTTCTCGCTTGACACACAGCTTCCGCCGAACCGCGACCGACGTGGTCGA
GGAGTTCATCGGCAACATCGAGACATAAAGGATGAGAGTACAGCGACGAGAACGCCCTGAAGGGC
ATCTCGCTGCTGTTACGGTATGCCAGCAGCTGGTGGCAAGGCGTCCGCAAGGAGGCCACCACGTGGA
AGGAAGCCATCGCTCATCCGCAACACTTCTGCCACCAAGGCCCTACCAGATCTACATGGAATT
CTTCCAAAACAAGCAGGACGACCATGACCCATTGACACCTCGTATCCAGAAGCGAGCGCTGCTGCC
CAGCTGCCAGCGGTGCCACGACGAGGAAACGGAACGGATCTCTGTTGGTCTGCTGAACATCAAGT
ACCGCAAGCACATCTCCGCCACAGTGTCCATACCTTCAGGATCTC

gi|3946290|gb|AI296873.1|;

CTACACTGGCTTGTCCGCCGACTGAACCAAGATTAATTGATCACCTAACCTCACACAGCAGCGAAAT
GGCCCAGCTTACACAGATGACCAACGAGCAGCTCCCGAGCTGATGAGCTGTAAGAGCGGCCGCGTG
GGCGCCGCCGGAAAGTGCAGCAGCAGCCGGAGGAGCAGACGCCAGCAGAGGCAAAGGCAACTTCTCGCTT
GCACACACAGCTTCCGCCGAACCCGCGACACGACGTGGTCAGGAGTTCATCGGCAACATCGAGACATA
CAAGGATGAGAGTACAGCGACGAGAACGCCCTGAAGGGCATCTCGCTGCTGTTACGGTATGCC
AGCACCTGGTGGCAAGGCGTCCGCAAGGAGGCCACCACGTGGAAGGAAGGCCATCGCTCATCCGCGAAC
ACTTCTGCCACCAAGGCCCTACCAAGGATCTACATGGAATTCTCCAAAACAAGCAGGACGACCATGA
CCCCATTGACACCTCGTATCCAGAAGCAGCAGCGTGTGGCCAGCTGCCAGCGGTGCCACGACGAG
GAAACGGAACGGATCTCTGTTGGTCTGCTGAACATCAAGTACCGCAAGCACATCTCCGCCACAGTG
TCCATACCTTCAGGATCTCTGGAAC

gi|15509291|gb|BI613766.1|;

ACCATGGTTCAAATCACGGCCGCATTGCTACACTGGTTGTCCGCCGACTGAACCAAGATTAATTG
ATCACCTAACCTCACACAGCAGCGAAATGGCCAGCTTACACAGATGACCAACGAGCAGCTCCGCGAGC
TGATCGAAGCTGTAAGAGCGGCCGCGTGGCGCCGCCGGAAAGTGCAGCAGCAGCCGGAGGAGCAGACG
CAGCAGAGGCAAAGGCAACTTCTCGCTTGACACACAGCTTCCGCCGAACCCGCGACCGACGTGGTC
GAGGAGTTCATCGGCAACATCGAGACATAAAGGATGAGAGTACAGCGACGAGAACGCCCTGAAGG
GCATCTCGCTGCTGTTACGGTATGCCAGCACCTGGTGGCAAGGCGTCCGCAAGGAGGCCACCACGTG
GAAGGAAGCCATCGCTCATCCGCAACACTTCTGCCACCAAGGCCCTACCAAGATCTACATGGA
TTCTCCAAAACAAGCAGGACGACCATGACCCATTGACACCTCGTATCCAGAAGCGAGCGCTGCTGG
CCCCAGCTGCCAGCGGTGCCACGACGAGGAAACGGAACGGATCTCTGTTGGTCTGCTGAACATCAA
GTACCGCAAGCACA

gi|4419244|gb|AI516144.1|

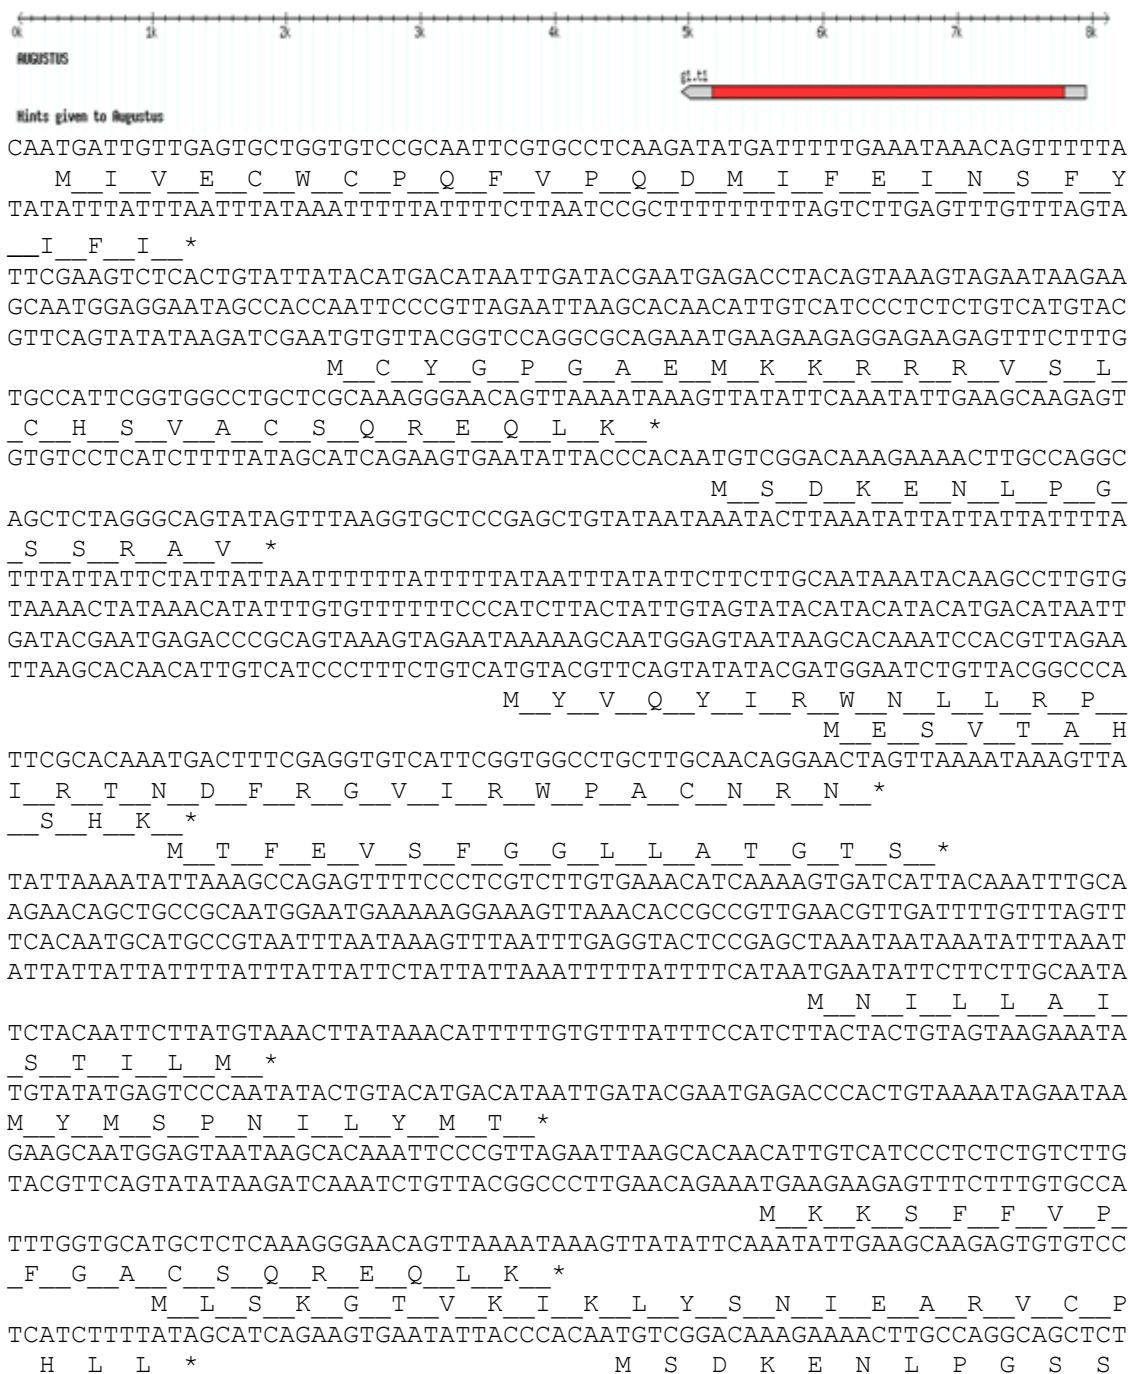
CTACACTGGCTTGTCCGCCGACTGAACCAAGATTAATTGATCACCTAACCTCACACAGCAGCGAAAT
GGCCCAGCTTACACAGATGACCAACGAGCAGCTCCCGAGCTGATGAGCTGTAAGAGCGGCCGCGTG
GGCGCCGCCGGAAAGTGCAGCAGCAGCCGGAGGAGCAGACGCCAGCAGAGGCAAAGGCAACTTCTCGCTT
GCACACACAGCTTCCGCCGAACCCGCGACACGACGTGGTCAGGAGTTCATCGGCAACATCGAGACATA
CAAGGATGAGAGTACAGCGACGAGAACGCCCTGAAGGGCATCTCGCTGCTGTTACGGTATGCC
AGCACCTGGTGGCAAGGCGTCCGCAAGGAGGCCACCACGTGGAAGGAAGGCCATCGCTCATCCGCGAAC
ACTTCTGCCACCAAGGCCCTACCAAGGATCTACATGGAATTCTCCAAAACAAGCAGGACGACCATGA
CCCCATTGACACCTCGTATCCAGAAGCAGCAGCGTGTGGCCAGCTGCCAGCGGTGCCACGACGAG
GAAACGGAACGGATCTCTGTTGGTCTGCTGAACATTAAGTACCGGAAGCACATTCCGCCACAGTGT
CCATACCTTCAGGATCTCCT

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 14 sORFs. Se pueden observar varias repeticiones en tandem y varias desplazadas. Los sORFs noveno, décimo, decimoprimer, decimosegundo, decimotercero y decimocuarto son duplicaciones desplazadas de los sORFs primero, segundo, tercero, cuarto, quinto y sexto, respectivamente. La transcripción se basa en la presencia de 10 ESTs en la base de datos pública y la probable traducción en la presencia en bases de datos de un péptido

definido por espectrometría de masas que cumpliría con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación. Esto significa que al menos uno de los sORF codificado por este transcripto es traducido.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_36



CGGACAGTATAGTTAAGGTACTCCGAGCTGTATAATAACTAAATATTATTATTATTATTATT
 R T V *
 ATTCTATTATTAATTTTATTTTATAATTATTCCTGCAATAACACGCCTTGAGTAAAAC
 TATAAACATATTGCGTTTCCCATTACTATTGAGTATAACATACATGACATAATTGATACG
 AATGAGACCCGAGTAAAGTAGAATAAAAAGCAATGGAGTAATAAGCAAAATCCACGTTAGAATTGAGC
 ACAACATTGTCATACCTTCTGTCATGTACGCTAGTATACGATGGAATCTGTTACGGCCATTGCA
 M Y A Q Y I R W N L L R P I R
 M E S V T A H S H
 CAAATGACTTCGAGGTGTCACTGGTGGCCTGCTGCAAAGGGACCAGTAAATAAGTTATATTAA
 T N D F R G V I R W P A C K G N Q L K *
 K *
 M T F E V S F G G L L A K G T S *
 AATATTAAAGCCAGAGTTCTCCTCGTCTGAAACATCAGAAGTGTACATTACAAATTGCAAGAAC
 GCTGCCCAATGGAATGAAAAGGAAATTAAACACCGCCGTTGAACGTTGGTTTTAGTTTACAAT
 GCATGCCGTAATTAAATAAGTTAATTGAGGTACTCCGAGCTAAATAATAATTTAAATATTAA
 TTATTATTATTATTATTCTATTAAATTTCATAATGAATATTCTTCTGCAATATCTACAA
 M N I L L A I S T
 TTCTTATGTAAACTTATAAACATTGGTTATTCCATCTTACTGTTGAGTAAGAAATATGTATAT
 I L M *
 M Y M
 GAGTCCCACAATACTGTACATGACATAATTGATACGAATGAGACCTACAGTAAAGTAGAATAAAAAGCAA
 S P T I L Y M T *
 TGGAAGAATAGCCACAAATTCCGTTAGAATTAGCACACATTGTCATTCTCTGTCATGTACGTT
 M Y V
 AGTATATAAGATCGAATGTGTACGGTCCAGGCGAAGAAATAAGAAGAGGAGAGTTCTTGTGCC
 Q Y I R S N V L R S R R R N K E E E K S F F V P
 M C Y G P G E E I K K R R R V S L C
 ATTGGTGGCCTGCTCGAAAGGGACAGGTTAAATAAGTTATATTAAATATAAGCAGGAGTGTGT
 F G G L L A K G T G *
 H S V A C S Q R E Q V K *
 CCTCGTCTGTGCAACATCAGAAGTGTACATTACAAATTGCAAGAACAGCTGCAGCACTGGAATGAAA
 AGGAAAGTTAAACACCGCCGTTGAACGTTGATTTTTAGTTTACAATGATGCATGCCATTAA
 GTTTAATTGAGGTACTCGAGCTAAATAATAATTAAATATTAAATATTATTATTATTATTCTA
 TTATTAAATTTCGCAATCTACAATTCTATGAAACTTATAACATTGGTTATTCCATCT
 ACTATTGAGTAAGAAATATGTATATGAGTCCAAATACTGTACATGACATAATTGATACGAATGAGAC
 M Y M S P N I L Y M T *
 CCACGTAAAATAGAATAAGAAGCAATGGAGTAATAAGCACAAATTCCGTTAGAATTAAAGGTACTC
 CGAGCTGTATAATAACTAAATATTATTATTATTATTATTATTATTAAATTAAATTAAATTAA
 TATAATTATATTCTTCTGCAATAACACGCCTTGAGTAAACTATAACATATTGCTTTTCC
 CATTTACTATTGAGTATAACATACATGACATAATTGATACGAATAAGACCCGAGTAAAGTAGAA
 TAAAAGCAATGGAGTAATAAGCAAAATCCACGTTAGAATTGAGCACAACATTGTCATACCTTCTGTC
 ATGTACGCTAGTATACGATGGAATCTGTTACGGCCATTGCAACATGACTTCGAGGTGCCATT
 M Y A Q Y I R W N L L R P I R T N D F R G A I
 M E S V T A H S H K *
 M T F E V P F
 GGTGGCCTGCTGCAAAGGGAAACCAGTAAATAAGTTATATTAAATATTAAAGCCAGAGTTCTCCT
 R W P A C K G N Q L K *
 G G L L A K G T S *
 CGTCTGTGCAACATCAGAAGTGTACATTACAAATTGCAAGAACAGCTGCCAATGGAATGATAAAGG
 AAAGTTAAACACCGCCGTTGAACGTTGATTTTTAGTTTACAATGATGCCGTAATTAAATAAGTT
 TAATTGAGGTACTCGAGCTAAATAATAATTAAATATTATTATTATTATTGTTATTCTATTAA
 TAAATTTCATAATGAAATTCTTCTGCAATATCTACAATTCTATGAAACTTATAACAT
 M K F L L A I S T I L M *
 TTTGTGTTATTCCATCTTACTATTGAGTAAGAAATATGTATATGAGTCCAAATACTGTACATGA
 M Y M S P N I L Y M
 CATAATTGATACGAATGAGACCTACAGTAAAGTAGAATAAGAAGCAATGGAGGAATAGCCACCAATT
 T *
 GTTAAAGCACAACATTGTCATCCCTCTGTCATGTACGTTAGTATATAAGATCGAATGTGTT
 M C Y
 CGGTCCAGGCGCAGAAATGAAGAAGAGGAGAAGAGTTCTTGTGCCATTGGTGGCCTGTCGCAAAGG
 G P G A E M K K R R V S L C H S V A C S Q R
 GAACAGTAAAGTATATTCAAAATTGAGCAAGAGTGTGTCCTCATTTTATAGCATCAGAA

E Q L K *
 GTGAATATTACCCACAATGTCGGACAAAGAAAATTGCCAGGCAGCTAGGGCAGTATAAGGTG
 M S D K E N L P G S S R A V *
 CTCCGAGCTGTATAATAAATACTTAAATATTATTATTATTATTATTCTATTATAATTTTTAT
 TTTATAATTATATTCTTCTGCAATAAACATACAGCCTTGTGAAAATACATACAGCAGTAAGTA
 TCCCACATCTACTATTGTAGTACATACATACATGACATAATTGATACGAATGAGACCCGAGTAAGTA
 GAATAAAAAGCAATGGAGTAATAAGCACAACATCCACGTTAGAATTAAGCACAACATTGTACCCCTTCT
 GTCATGTACGTTCACTATACATGGAATCTGTTACGGCCATTGACAAATGACTTTGAGGTGTCA
 M Y V Q Y I R W N L L R P I R T N D F R G V
 M E S V T A H S H K *
 M T F E V S
 TTCGGTGGCCTGCTTGCAACAGGAACAGTTAAATAAAGTTATATTAAATATTAAAGCCAGAGTTTC
 I R W P A C N R N *
 F G G L L A T G T S *
 CCTCGTCTTGTGAAACATCAAAGTGTACATTACAAATTGCAAGAACAGCTGCCAATGGAATGAAA
 AGGAAAGTTAACACCGCCGTTGAACGTTGATTTGTTAGTTCACATGCATGCCAATTTAATAAA
 GTTTAATTGAGGTACTCGAGCTAAATAATAATTTAAATTGTTGTTGAAAGGTGCTCCAAG
 TGTGAAACACTGACAACCATTGGGAAGATCCTAATCTCACCCAAACTCAGCGATTGAGAGCAAAGG
 CGGAATGAGTAACCGCAAATAAAAGTCTTGAGCCGAGCGTCCGAACACGAAGAAGTTTATTGAAAC
 M S K R E I K S L E P S V R T R R S F I *
 TGAAACTGATACACATAAAATGCCAGCTCATGCCGCTGCTTATTACTAATATATACATACATACA
 GTTCATGTGTATGTATGTTCTACAGAATTACATATGCACATGTGCAAATGCCCTATATTCAAC
 M Y V L I Q N Y I C T C A N G L Y S T
 M F S Y R I T Y A H V Q M A Y I Q
 ACACATGTGGCATTGCCATATTCAACAGCCTCCTCAATGCCAACATGTTACAAAAATTAAACAAA
 H M W A L P I F N S L P Q C Q H V Y K N *
 H T C G H C L Y S T A F L N A N M F T K I K T N
 TTTAACATTTCTACAAACCCATTATGCTTCCCTTGAAAGATTCTTGTCTACATGTCTGCTATCATCT
 L T F S * M S A I I
 CATTCGTAGAAGTGTACTCTAACACACGTGACCCCTTTCATGACTCTCTAAATGAAATGATATCGAAT
 S F V E V Y S N T T * M I S N
 GTCGATGTGCTTCGTCCTAGAGTGATGAACCGGGTCTCGCTAACGTGCGCACTCAGGTTGTCGCCA
 V D V L R P R V M N R V L R *
 TGCATAACCGTCGGGTCTCAGATCACCGCATCTCCACTATTAGCCTCGTAAAGCTATAGCTT
 M H N R R G L Q I T A S D L H Y *
 CCTTGCAAGCCGTGGTCAGAGCCATATACTCGGCTTCAGTACTGCTCAACGCCACGCTCTGCTTCTC
 GGACCTCCATGATACTGGTCCGCCAGACAGGAAAACACATACCCGTATATGACTTCGGTCAAACGG
 M I L V R Q T G K T H T L Y M T F G P N G
 TCGCCTCCCCAATTCGATCCACAAAGCCGGTAAATGCCCTGACCGCACTTTGATAATGCAGCTTGACGT
 R L P N L H P Q S R * M P D R T F D N A A *
 CCACAGTTGACGCCAAGTACCGGAGGATGTGCTCACAGCCACCATGTGCTCAGAATGCCGGTCTTATT
 M C F T A T M C S E C G S L F
 M R V L I
 CCTCTGAGCCAACCTGCCACCGAATGTAGTATGTCGGCTGGTAGTAAGCCCAAGCCACATTAGCTCA
 L *
 P L S Q L R H R M * M S G L V V S P S H I S S
 CCAATTGTAGACTGATACTGCCCTCGCTGACCTCTGGCACTGCTCACCCCGCGCACAAACTTGATGCC
 P I V D * M P
 CTGCATCCAAAGGTGTCGCTGGTCTACAGTTCTCGCTGCCATATGCCCGCAATAGTTCTGATATA
 C I Q R C R R W S T V L A A I C P Q *
 TTGCGAATGCCCAAAGTGTATTCTCCAAGGTGCCATCTGTTGACCTCCATGCCATAAGAACAAATGC
 M A Q S D F S K V A I S L H L H A *
 M P K N K C
 M
 AGTGGACCCCTTGTCCGTGCACTCGAAAGACTCTGAAATCTGGCTTCAGATCCTCCATATCTCTTGT
 S G P L S V H S K D S E I L A F R S S I S S L
 Q W T L V R A L E R L *
 ACTGGCACGCTAGAATTAAATCATCAACATATACTAACAGATGAGCATCAGATTACCTGACCACTTGCTG
 D W H A R I K S S T Y T K M S I R L P *
 ATAAAGACATGGTTCATGATTACAGGCCCTAAATCCCAAGTCTTTAGAACACCGTCGAGCTGGAGTTC
 M I T G L K S Q V F *

CACTCTCTGCCTGACTGCTCAAGCCGTATATTGCCTTCAGCAATAACACCTGGTCGGGATTAGCAG
 CATCTGTGAACCCTGGGCTGCTCATGTACACAGTATCCTTAGCTCGTATTAAAGTACGCCGTGCA
 M_Y_T_V_S_F_S_S_L_F_K_Y_A_V_H
 TACGTCCATGTGATGCAAGTACAATTGCATCTGCTGCCAATGCCAAATGAGCCTCACACTCTCGAGC
 T_S_M_* M_Q_V_Q_L_H_L_C_C_Q_C_Q_N_E_P_H_T_L_E_
 M_S_L_T_L_S_S_
 CTGCACACGGGTGAAAAAGTCTCGAAGTAGTCCACTCGAACCTCTGCGAACACCCCTTGCTACTAGTC
 P_A_H_G_*
 L_H_T_G_E_K_V_S_K_*
 GTGCTTGAAGCGCTCAATTCTACAGAGACGTCTCGTTCAGGAATACACCCACTGCAAGCCACACA
 CGCGCAGTTCTGGTAAGTCAGCCAGCTTCATGTCTCATTGCAAGTAGCGCCTGTACTCCAGGCC
 M_S_H_L_Q_V_A_P_C_T_P_G_P
 ATTGCCTCTTCCCACTTGCAAGAATACTGCAATTGATGGCCTCCTCATAGGACTTGGGAATTTCGACGT
 L_P_L_P_T_L_Q_N_T_A_N_*
 CGCTAGCCATCAACACGCCAAGTACATTGATTGCTTCTCGGGGCCCTGGTCTGCCGTCCGAAACAAAT
 CTTTGGCCGTCCAGGCCACATGTACTTCAGCTTCTGTCTCAGCTGCACTCTCATAGTCGTGCTG
 CTGCCACGGGTTCTGTATCGTCACCTTCCGTGCATTGAATCACTCTGCGGCTCCGGTCTAGTTG
 CGGGAAACTGGAACTCAATGGTATTCCATGATTACCAAACCTACAGACTCATCAAAAAGGACATCTCG
 CTTCTCGATCACACACCCTCTCTTGTCAAACAGACGGTACCCCTAGCGCTATTGAATATCCAATC
 ATACGATATTCTTCTTGGATTGAATTGCAATTGCACTTGTCCATGCCACTGCTATGG
 M_D_S_F_V_Q_C_H_C_Y_G
 M_P_L_L_W
 CACCAAAAACCTCAAGTGGCTACTGCTGGTATTTCGGTCCACTCTTCATAGGGGTTTGCTTTG
 T_K_N_P_Q_V_A_H_C_W_Y_F_S_G_P_L_F_H_R_G_F_A_L_
 H_Q_K_P_S_S_G_S_L_L_V_F_F_R_S_T_L_P_*
 TAATGCTCTGCTCGTTGATCGGTTCTCAGATACACCGCAGTGTATTATCGCCTCAGGCCATAGAGCCTCA
 * M_L_C_S_L_I_G_S_S_D_T_P_Q_C_L_S_P_Q_P_I_E_P_H
 CCCAACTCCGATTGCAGCAACATGCACCTAGCATTCTACTAGCGTGGGTTGGCTCGTCTGCAACTC
 P_T_P_I_A_A_T_C_T_*
 CATTGGTTGGGGAGTGTGGAATAGTCAGCTGTAGCGATCCATGTGCCTTAAATAGTCATCAA
 AACATTATTGACGAACCTACACCATTATCGCTCCGGATACATTATCTTACCTGTTGCTCGCTCG
 ACCAGTTCTAAACTCGACAAACTTAGTGAAGACTTCGCTCTTCCGCAAGAAATATACAAAATCC
 GCCTGGACTTGTGCTATGAAAGTACTTGATCCAGCAAGTGACGGTGTGCTAAATGGCCC
 M_A
 GCACAGGTCTGAATGGATCATATCCAACAGCTCTCAGCTCTGCTCTCGTTATCTCGAAATGGTTGC
 R_T_G_L_N_G_S_Y_P_T_A_L_Q_L_C_S_S_L_S_S_E_M_V_A
 ACATGGATTTCGCCAGCATGCACGTCTGCATACTGCGTCTGGTTGAAACGACCTTTCAACACCGT
 H_G_F_L_P_A_C_T_S_C_I_L_R_L_V_*
 ACACCATCTTCTCCTCACCATCTCCTGAGGCTGCTTGTATTCAAATGCCATACCTTTATGCCATAG
 TGAACCATCAGCATCAACGGCCGCAAAACAACGTGTTATGTTCCCTGAAACATATACAAATTACAGCT
 M_F_P_L_K_H_I_Q_I_T_S_
 CTCATTACACGCAGTATTGCTCGCCTTGAATGACGTAGCGTAATGTGGTCCAAAATTGACAAAAC
 S_H_Y_T_Q_Y_S_L_A_F_L_N_D_V_S_V_M_W_S_K_I_D_K_T
 ATTATATACTGAGCTGCACGGCTGACTGACATAAAGTTGCCGTTCAAATCTGGACGAAGAGTACGTTATT
 F_I_L_S_C_T_A_D_*
 CAATACCAAGAGTACATAAATCAGTCTCAGCTTCACTGTTCC

Para la región genómica 2R_36, el programa Augustus Gene Prediction predijo una estructura compuesta por 1 exón de 3010 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido VAISLHLHA con una probabilidad de $p=0.026$ y un valor E=0.000229369724183258; para el péptido HIQITSSHYTQYSLAFLNDVSVMWSKIDK con una probabilidad de $p=0.081$ y un valor E=3.03744367302705e-05; para el péptido LYSNIEARVCPhLL con una probabilidad de $p=0.092$ y un valor E=4.09554946328805e-06; para el péptido VSLCQSVACSQREQLK con una probabilidad de $p=0.061$ y un valor E=0.000449345514508928; para el péptido TNTIGVEFGGLAK con una probabilidad de $p=0.088$ y un valor E=0.000508807322509452; para el péptido SDKEILPGSSR con

una probabilidad de $p=0.075$ y un valor $E=0.000636722643072906$; para el péptido ESVTELSHK con una probabilidad de $p=0.054$ y un valor $E=0.000450049714182085$; para el péptido TYHGAPVMVLR con una probabilidad de $p=0.003$ y un valor $E=1.48439998597412e-06$; para el péptido SDKEILPGSVEITL con una probabilidad de $p=0.003$ y un valor $E=0.000794405317951904$; para el péptido GIIDYSSERAD con una probabilidad de $p=0.091$ y un valor $E=0.000241072869175419$; para el péptido MIVECWCPQFVPQDMIFEINSFYIFI con una probabilidad de $p=0.063$ y un valor $E=0.000698357520840089$; para el péptido SLTLSSLHTGEK con una probabilidad de $p=0.021$ y un valor $E=0.000685695690553343$; para el péptido STLTDNIFILIPK con una probabilidad de $p=0.07$ y un valor $E=0.000401250037091144$; para el péptido GYLSLFGCFHSERTTVPQ con una probabilidad de $p=0.003$ y un valor $E=0.000241335605173436$; para el péptido RFQSVGEELSGLATVTFLCLLV con una probabilidad de $p=0.052$ y un valor $E=2.57365994909838e-05$; para el péptido RACTQSSSNNTATLQYMSTI con una probabilidad de $p=0.1$ y un valor $E=0.000840819062297212$; para el péptido ILDNPLNRLIGR con una probabilidad de $p=0.012$ y un valor $E=0.000104857096110441$; para el péptido MQUELTGVCGV con una probabilidad de $p=0.075$ y un valor $E=0.000190342314803903$; para el péptido VMFISGFYYRPIKLFSFWVHK con una probabilidad de $p=0.018$ y un valor $E=0.000135603127855901$; para el péptido LVFYQKLYPNIECCQPIVLESLVFATVYQEDNEVSFFL con una probabilidad de $p=0.066$ y un valor $E=0.000345276025242189$; para el péptido MDLTVSIGSLSSPDK con una probabilidad de $p=0.002$ y un valor $E=1.52517535190515e-05$.

Evidencia de ESTs:

gi|4447938|gb|AI533803.1|;

```
AATGCATGCCGTAAATTAAAGTTAATTGAGGTACTCCGTGCTAAATAATAAAATTAAATATTAAATATTAA
TTATTATTATTATTATTCTAATATTAAATTAAATTTCATAATGAATATTCTCTTGCAATATCTA
CAATTCTTATGTAAACTTATAAACATTGGTGTATTCCATCTTACTGTTGTAGTAAGAAATATGTA
TATGAGTCCCACAATACTGTACATGACATAATTGATACGAATGAGACCTACAGTAAAGTAGAATAAAAAG
CAATGGAGGAATGCCACAAATTCTGTTAGAATTAAAGCACAACATTGGCATCCCTCTGTATGTAAG
TTCAGTATATAAGATCGAATGTGTTACGGTCCAGGCAGAAATGAAGAAGAGGAGAAGAGTTCTTGT
GCCATTGGTGGCTGCTCGAAAGGGAACAGGTTAAATAAGTTATATTAAATATAAAAGCAGGAGTG
TGTCTCGTCTTGTCAACATCAGAAGTGTACATTACAAATTGCAAGAACAGCTGCCAATGGAATGA
AAAAAGAAA
```

gi|13771353|gb|BG639775.1|

```
ACTCAAGGCGTGTATTATTGCAAGAAGAATATAATTATAAAAATAAAATTAAATAGAATAATAA
ATAAAATAAGGATAAGGGTTAAGTATTATTACAGCTCGGAGTACCTAAACTATACTGTCCGAGAGC
TGCCTGGCAAGTTCTTGCCGACATTGTGGTAATTCACTTCTGTGCTATAAAAGATGAGGACA
CACTCTGCTCAATATTGAATATAACTTATTAACTGTTCCCTTGAGAGCATGCACCAAATGGCA
CAAAGAAACTCTCTCATTCTGTTCAAGGGCCGTAACAGATTGATCTTATATACTGAACGTACAAGA
CAGAGAGGGATGACAATGTTGTGCTTAATTCTAACGGGAATTGTGCTTATTACTCCATTG
```

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 54 sORFs. La transcripción se basa en la presencia de 2 ESTs en la base de datos pública y la probable traducción en la presencia en bases de datos de 21 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación. Esto significa que al menos dos de los sORFs codificados por este transcripto son traducidos.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por

espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_44



```

-S-Y-S-P-A-L-L-*  

-A-I-V-P-H-Y-C-K-I-K-S-A-R-G-R-C-R-L-C-I-*  

TATTGCGCAAAAAACTATTAAGTCGAGTTTAGACGCATCACCATAATTTATAAATAAAAGCC  

AATGCACAAGTCAAAAGTATTCACTTTAATAAGACATCAAGAACAACTACAGTTGAATCTTGAT  

M-H-K-S-K-V-F-H-F-L-I-R-H-Q-E-Q-L-Q-L-N-L-L-Y  

CTAATTTCACGCCATTTAATTACCCCCATGGAGGGTGGCCCCAGGTCTTGTGATTATT  

L-I-F-T-P-F-N-L-P-P-W-R-V-A-P-G-L-L-S-I-I-*  

M-E-G-G-P-R-S-L-V-D-Y-T-*  


```

Para el gen 2R_44, el programa Augustus Gene Prediction predijo una estructura compuesta por 3 exones de 103 pares de bases el primero, 30 pares de bases el segundo, y 97 pares de bases el tercero, y 2 intrones de 56 pares de bases el primero y 939 pares de bases el segundo .

Se encontró acuerdo con espectros de masas para el péptido CIISRANIYLFNVVQHLIcon una probabilidad de $p=0.083$ y un valor E=0.000666519259242421; para el péptido SKVFHFLIRcon una probabilidad de $p=0.033$ y un valor E=7.09239329981059e-05; para el péptido VAPGLLSIIcon una probabilidad de $p=0.026$ y un valor E=0.000142575835728852.

Se halló evidencia de ESTs:

gi|38626652|gb|CK134716.1|;

```

ATTATTTCCAGGGCAAATATTATTTAACGTGGTTCAACATTAAATTAGCTAAAATTACGCAT  

TTCATGATTCCATGGGTGAAAGCGATGCATCCAATCCTGGTTGTCTATGTGCTTGCCTACGTGGAATTG  

TAAAAAATAGTTAGAACCTACTTGTGTCGCCTCAACCTGGCTACAAGCGTTAGATAGAACAGCCT  

GTCTGAGGAGAATTCTCGACATTGGCGACTGGGCAAAGGGGACAGCTCTCAAATCAAACGCGGAT  

GCCAACGAGTCAGGCCGTATCCTCTTGATCCTGAACCTCAAAGAATTGGATGTGGCTTAAGGGAATA  

AATACGCCACATCAGTAGACTTGGATGACACATTCCGTATCAGGCCCTCTCACGGCATCCAAAAGTTTC  

CACTCTAGCCGGTCCGAATTCCAGATCTTGAATATGGTACTTGGCAGCTGGACAATGGGATTA  

GCTATAGTCGCATTATTGAAAGCGCTAGAGGGCCTGTCGCCTTGTATATAAGTATTAT  

ATTGCGAAAAAAACTATCAAGTCGAGTTTGCACACGTCAAAAGTATTCACTTT

```

gi|15470698|gb|BI579276.1|;

```

AGTTCAAAATGCAGCTCATCGTGAAATTACTGATTGTCCTTGGCATTATTGCTGTTCTTATGGAG  

AAGTAAAACATCCACAAAGATCCTGGAGCCACCTTCATGGCGTAAATTAAAGTGGCGTAAAATTAGAT  

ACAAAAGATTCAACTGTAGTTGTTCTGATGTCTTATTAAAAAGTGAATACTTTGACTTGTGCAAAA  

ACTCGAACATTGATAGTTTGCACATATAACTTATACAAAGGCACAGCGCCCTCTAGCGCTT  

TTCATTTACAATAATGCGGACTATAGCTAATCCCATTGTCCTCAGCTGCCAAGTACCATATTCAAAGA  

TCTGAAATTGGACCGGCTGAGAGTGGAAACTTTGGATGCCGTGGAGAGGCCCTGATACGGAATGT  

GTCATCCAAGTCTACTGATGTGGCGTATTATTCCCTTAAGGCCACATCCAAATTCTGGAGTTAGGAT  

CAAGAGGAGATACGCCCTGACTCGTGGCATCCGCAGTTGATTGGAGAGCTGTCCCCTTGCCCCAGT  

CGCCCAATGTCGAGATATTCTCCTCAGACAAGGCTATTCTACACGCTGTAGGCCAGGTTG

```

gi|15470762|gb|BI579340.1|;

```

AGTTCAAAATGCAGCTCATCGTGAAATTACTGATTGTCCTTGGCATTATTGCTGTTCTTATGGAG  

AAGTAAAACATCCACAAAGATCCTGGAGCCACCTTCATGGCGTAAATTAAAGTGGCGTAAAATTAGAT  

ACAAAAGATTCAACTGTAGTTGTTCTGATGTCTTATTAAAAAGTGAATACTTTGACTTGTGCAAAA  

ACTCGAACATTGATAGTTTGCACATATAACTTATACAAAGGCACAGCGCCCTCTAGCGCTT  

TTCATTTACAATAATGCGGACTATAGCTAATCCCATTGTCCTCAGCTGCCAAGTACCATATTCAAAGA  

TCTGAAATTGGACCGGCTGAGAGTGGAAACTTTGGATGCCGTGGAGAGGCCCTGATACGGAATGT  

GTCATCCAAGTCTACTGATGTGGCGTATTATTCCCTTAAGGCCACATCCAAATTCTGGAGTTAGGAT  

CAAGAGGAGATACGCCCTGACTCGTGGCATCCGCAGTTGATTGGAGAGCTGTCCCCTTGCCCCAGT  

CGCCCAATGTCG

```

gi|14631551|gb|BI165744.1|;

```

GCAGTTCCAAAATGCAGCTCATCGTGAAATTACTGATTGTCCTTGGCATTATTGCTGTTCTTATGG  

AGAAGTAAAACATCCACAAAGATCCTGGAGCCACCTTCATGGCGTAAATTAAAGTGGCGTAAAATTAG  

ATACAAAAGATTCAACTGTAGTTGTTCTGATGTCTTATTAAAAAGTGAATACTTTGACTTGTGCAA

```

AAACTCGAACTTGATAGTTTTGCGCAATATAACTTATACAAAGGCACAGGCCCTAGCGCTTTCATTTACAATAATCGGGACTATAGCTAATCCCATTGCTCCAGCTGCCAAGTACCATATTCAAAA GATCTGGAAATTGGGAACCGGCTGAGAGTGGAAACTTTGGATGCCGTGGAGAGGCCCTGATACGGAAT GTGTCATCCAAGTCTACTGATGTGGCGTATTATTCCCTAACCCACATCCAAATTCTGGAGTCANGA TCAAGAGGAGATACGGCCTGACTCGTGGCATCCGAGTTGGAGAGCTGCCCCCT

gi|15325207|gb|BI485029.1|;

AGTTCCAAAATGCAGCTCATCGTCAAATTACTGATTGTCCTTGGCATTATTGCTGTTCTTATGGAG AAGTAAAACATCCACAAAGATCCTGGAGCACCTCCATGGCGTAAATTAAAGTGGCGTAAAATTAGAT ACAAAAGATTCAACTGTAGTTGTTCTGATGTCTTATTAAAAAGTGAATACTTTGACTTGTGCAAAAA ACTCGAACATTGATAGTTTTGCGCAATATAACTTATACAAAGGCACAGGCCCTAGCGCTT TTCATTTACAATAATCGGGACTATAGCTAATCCCATTGCTCCAGCTGCCAAGTACCATATTCAAAAGA TCTGGAAATTGGGAACCGGCTGAGAGTGGAAACTTTGGATGCCGTGGAGAGGCCCTGATACGGAATGT GTCATCCAAGTCTACTGATGTGGCGTATTATTCCCTAACCCACATCCAAATTCTGGAGTCAGGAT CAAGAGGAGATACGGCCTGACTCGT

gi|15469717|gb|BI578295.1|;

AGGGCCAAAGGGGAGCTCATCGTCAAATTACTGATTGTCCTTGGCATTATTGCTGTTCTTATGGAG AAGTAAAACATCCACAAAGATCCTGGAGCACCTCCATGGGGGAAATTAAAGTGGCGTAAAATTAGAT ACAAAAGATTCAACTGTGGGGGGGTGATGTCTTATTAAAAAGTGAATACTTTGACTTGTGCAAAAA ACTCGAACATTGATAGTTTTGCGCAATATAACTTATACAAAGGCACAGGCCCTAGCGCTT TTCATTTACAATAATCGGGACTATAGCTAATCCCATTGCTCCAGCTGCCAAGTACCATATTCAAAAGA TCTGGAAATTGGGAACCGGCTGAGAGTGGAAACTTTGGATGCCGTGGAGAGGCCCTGATACGGAATGT GTCATCCAAGTCTACTG

gi|48957813|gb|CO184932.1|

TGAAATTACTGATTGTCCTTGGCATTATTGCTGTTCTTATGAAGAAGTAAAACATCCACAAAGATC CTGGAGGCCACCTCCATGGCGTAAATTAAATGGCGTGAAAATTAGATACAAAGATTCAACTGTAGTTG TTCTTGATGTCTTATTAAAAAGTGAATACTTTGACTTGTGCAAAAACCTCGAAAAAAAAAAAAAAA AAAAAAAAAAAAAAAAAGAAAAAAAAGAAAAAAAAGAAAAAAAAGAAAAAAAAGAAAA

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 19 sORFs. Se pueden observar varias repeticiones en tandem y varias desplazadas. Los sORFs decimoquinto, decimosexto y decimoséptimo son duplicaciones desplazadas del octavo, noveno y décimo sORF, respectivamente. La transcripción se basa en la presencia de 7 ESTs en la base de datos pública y la probable traducción en la presencia en bases de datos de 3 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación. Esto significa que al menos 3 de los sORFs codificados por este transcripto son traducidos.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

2. REGIONES GENÓMICAS CON VALIDACIÓN SÓLO POR ESPECTROMETRÍA DE MASAS

Gen 2L_16



GTGATCTTAAATTTCAGGATGGCGAATTGTAGTAGGCTAGAGGTACATGTCGAGCGTTGACATTTCT
 TGTGCCTGATCTCCCATGGCAATTAAACTATTGAGTGAAGCGAATTCCAACCGCGTGCGCGATCG
 TCTGTATGCAACTGATCGTATTTCTACGCATCGCATTCTACACATGCTAGCTGGACTACACTAGGCGAC
 M_Q_L_I_V_F_S_T_H_R_I_L_H_M_L_A_G_L_H_*
 AGCGCGACAACGCCGTCGCCTCGACACTCGCCTCACTCGTAACGGTACTTGGGCCAGTC
 ATATTCTCGTGGTAGTCAAATTCTAAGAATGACCTCTCAATATAACCAACTATTGCGCAGCTGCGTCT
 M_T_S_Q_Y_T_Q_L_I_A_Q_L_R_L
 TGCAAGCACAGTGGTCAAACCATGTTAATAATGACAGACACGTACAGTGGTCAGAATAACATCCGTAAT
 A_S_T_V_V_K_P_C_* M_T_D_T_Y_S_G_Q_N_T_S_V_M
 GCGACACGGCCTCCTGACATAATACACGTCCCTCGTGTGTTAAATCTACCACATAAGTGATAATA
 R_H_G_L_P_D_I_I_H_V_L_V_C_C_L_K_S_T_T_*
 CTTCAGGATTCCAAGGCTCTGGATATTCTAAGAATGTTCCATTCTATTCTATTCTATTCTTTT
 M_F_S_I_Y_S_I_S_I_S_F
 ATTCTCAAATTCTTTGTCTACCTCATCGTTATCTCGTTAGCGGCAACAAGCAAAGGTCGAG
 *
 CTTCTTACCAATCAATAATTCAAAGGGCTAAACTTAGTCACAGATTAAATCGTCAATTCTACCTAG
 CTGCACTTCAGCCAACGCATCCTGCCATGATCTGACTAGACTCGACAGCGTTAGCATACCTTCAGG
 GTGCTCATGACACGTCCTACCTGACCGTTGCTCTACTTCACCTGTAGCAATTAAATGTAGATTAATT
 TTTGAGAGGAGCAAAGCTTTACTTGCAGAAACTACGTCCTGATCTGCTATAATTGAGT
 GGGTAAACCAAACAAGGACACGGCTGATTTACAGCCTTAATGCAGCTATCAGAATATACTATTAGTGTG
 M_Q_L_S_E_Y_T_F_S_V
 TGATGAAAATAACAAACTGGTGAAGGCATCTAAAGGACGATGAAATATTCTCAAATCATTGGCC
 *
 M_K_I_N_K_L_G_E_G_I_*
 ACTCAATTTCGCTGTGATGTCATATGTATCGTATGCCACGGTATTCTATTAGGAATAGGATTCA
 M_Y_R_M_P_R_Y_F_Y_F_R_N_R_I_Q
 TCAGCCTGCACTTTCCGCTAGTGGCTAGAAATTACATGTAATGCAATTCTACGAATCTACACA
 L_S_L_H_F_S_R_*
 CATATTAGGCATATTTCGAACCAAGTAATAACAATAGACTTTGCTTATGTTCTCAAGCACTGGAT
 TTCGAGAGAGAAAATCCACATGCGCAATTGCGCTCGCTTTATATACTCTATTGAAATCAAATGCCT
 GTAAAAACGCCAACCATCTATGCACCCCTCGGTGTTAAATCTAGTTGACGGCTGGCTTAAAGAATT
 ACAGTCAGTATGACTACAAATTACGTCCTGCAAATAATGCCGAAGTGTATTAGCATTACCACT
 M_Y_Y_K_F_T_S_L_Q_I_M_P_E_V_F_Y_S_I_Y_H
 GCTAACGTCCTCAGTCGTATGAAATGGTATTAGATTGCGGGAGACGTACACTACTGTAATACTCTA
 C_* M_V_F_R_F_G_G_R_R_T_L_T_V_I_L_Y
 CAACATGAGGTTATTGTCATTTATGTAACAGGATCGCTCCATACCAACTTGCGTCAGTATG
 N_M_R_F_I_V_N_F_M_* M_
 CAGCTCTATTGGTATTGCGGATCGAATATGATTAAACTGGCGTCTGGGTCATATAGTTATTCTT
 Q_L_Y_L_V_L_R_I_E_Y_D_*
 M_I_K_T_G_V_W_V_N_I_V_I_I_F
 ATTGCGCACCTGTTCATGCACTGGTAACCAAACAAAGTCAGTGTGTTCTAGATGTGAGAAGATA
 CAGAG_I_R_T_C_S_C_T_G_N_Q_T_K_S_V_F_F_L_D_V_R_R_Y_R
 GTTTAAGTGTGAGGAAATTAAACACAAATTGACGAAATATGTTGCTAAACCAATGAATTGCTTAG
 G_L_S_V_W_E_K_F_N_T_N_* M_N_C_L_S
 TTGTGAGACATTGGGGTGTGGTAATGCTTAAAGCTTGAATTTCGTGATTGGCCTGACTTCT
 C_E_T_F_W_G_D_G_N_A_F_K_A_*
 M_V_M_L_L_K_L_E_F_F_V_Y_L_A_*
 CCCTTGCTTATTCAAATCCGAGACTCTATTGAGAAACACTTAGTGACATTAAATG

M

AAAATCCAGCCTTACTTAATGTCTCCAACACTCTATGCAATCTAACTAGCGCATCTTCTTACTTCTGC
 _K_I_Q_P_Y_L_M_S_P_T_L_Y_A_I_*
 TATTATGAGAACATCATCAATATAACACAATTGCAAGTGTAGGCTAAATCTCCTAGGGCCTTCATTATA
 M_R_T_S_S_I_Y_T_I_A_*
 GCCCGCTGGAAAACAGATGGTGCCTTTCAAACCAAACGGCATTGCAAGAACTCGTATTGACCCTCTG
 M_V_R_F_S_N_Q_T_A_L_S_R_T_R_I_D_P_L
 GCGTTACAAACGCTGTTCAATTGAGTCCTCATGGACTGGAATTGATAAAAGCCGCTGCCATATC
 A_L_Q_T_L_F_V_Q_L_S_P_H_G_L_E_F_D_K_S_R_L_P_Y
 M_D_W_N_L_I_K_A_A_C_H_I
 TATGCACGAAAAATTTAGCACCCGAAGCCTAGCAATTGGTCTGAGATGAGGGCAATGGATACTTG
 L_C_T_K_N_I_*
 Y_A_R_K_I_F_S_T_P_K_P_S_N_L_V_*
 M_H_E_K_Y_L_A_P_R_S_L_A_I_W_S_E_M_R_G_N_G_Y_L
 M_D_T_C
 TCAGCCACTGTATTCATTAGCATGCGATAGTCCACACCCAGTCGATCGGTGCCATTCTTTTTTG
 S_A_T_V_F_S_F_S_M_R_*
 Q_P_L_Y_F_H_L_A_C_D_S_P_H_P_V_D_R_C_H_S_F_F_L
 ACTAGCATCATGGGACTAGCGAAAGTTGAACAGCTGGCGAATAAGCTTTAGTAATTAACTCAACTTTA
 T_S_I_M_G_L_A_K_V_E_Q_L_G_R_I_S_F_*
 CCCCGCATTGCTTTCTCTCACTAAGAGTTAAATTGTGCCATGTGATGCCAGCAAAGCA
 TATTGGGACAGCATTGTGATGCACTCCCTCTAGGCCTTACTAAAGTTATCATCAGGCTGCTACCT
 M_H_F_P_L_A_P_Y_L_K_L_S_S_G_C_Y_L
 TCGGGCATTATCAGCAAAATGAGATCCACTGTTGATACACCAAGCTGAGGCATCTGCACCAGCTCCCT
 R_A_F_Y_Q_Q_K_*
 CAGGATGAAACTTGGGAGAATTATATATTTCCCTTTCATCAGTTCCGATGCCATTGGTCTGCAT
 M_K_L_W_E_N_Y_I_F_S_L_F_I_S_F_R_C_L_W_C_L_H
 ATTTTGATGATCTCCATTAGGTTGTTGCACTTGAAAGCTGCCAGGTATGCATCGGTGATATT
 I_F_D_D_L_F_*
 M_I_S_I_R_L_L_F_C_T_C_K_A_A_R_Y_A_S_V_I_F
 TTAGGCAAAGCAGATCCCACTCTGATGTCGCAGCGTTGACATTCTTGTGCCATCTCCATGTTGG
 L_G_K_A_D_P_T_S_D_V_A_A_L_T_F_S_C_A_*
 CAATTAAACTATTGAGTGAAGCGAATTCCAACCGCGTGCAGTCTGTATGCAACTGATCGTATT
 M_Q_L_I_V_F
 TTCTACGCATCGATCTACACAGCTAGCTGGACTACACTAGGCGACAGCGCGAACAGCCGTC
 S_T_H_R_S_I_L_Y_T_R_*
 GCCTCACTCGTAACGGTACTTGGCGCCAGTCATATTCTCGTGGTAGTCAAATTCTAAGAATGACCTCT
 M_T_S
 CAATATAACCAACTCATTGCGCAGCTCGTCTTGCAGCACAGTGGTCAAACCATGTTAATAATGACA
 Q_Y_T_Q_L_I_A_Q_L_R_L_A_S_T_V_V_K_P_C_* M_T
 GACACGTACAGTACACATACATAAGTTCAAGTCTGATGTCAGTCATAATAGCAACATAGTATATAACATTAAGTCATTGT
 D_T_Y_S_T_H_T_*
 TCGTTTCGGGTGCATTCTCTGTTGCAACATCGGCTCTGTAGCAACAAGCATAGAGGCAGATCGCA
 AACGGAGAGGGAGTCAGTCGAATGCTAAAGCTGAACACGGGAAGTAACAAATAACCAAAAGAGTCGACT
 M_L_K_L_N_T_G_S_N_K_*
 CCTGCTTTGTG

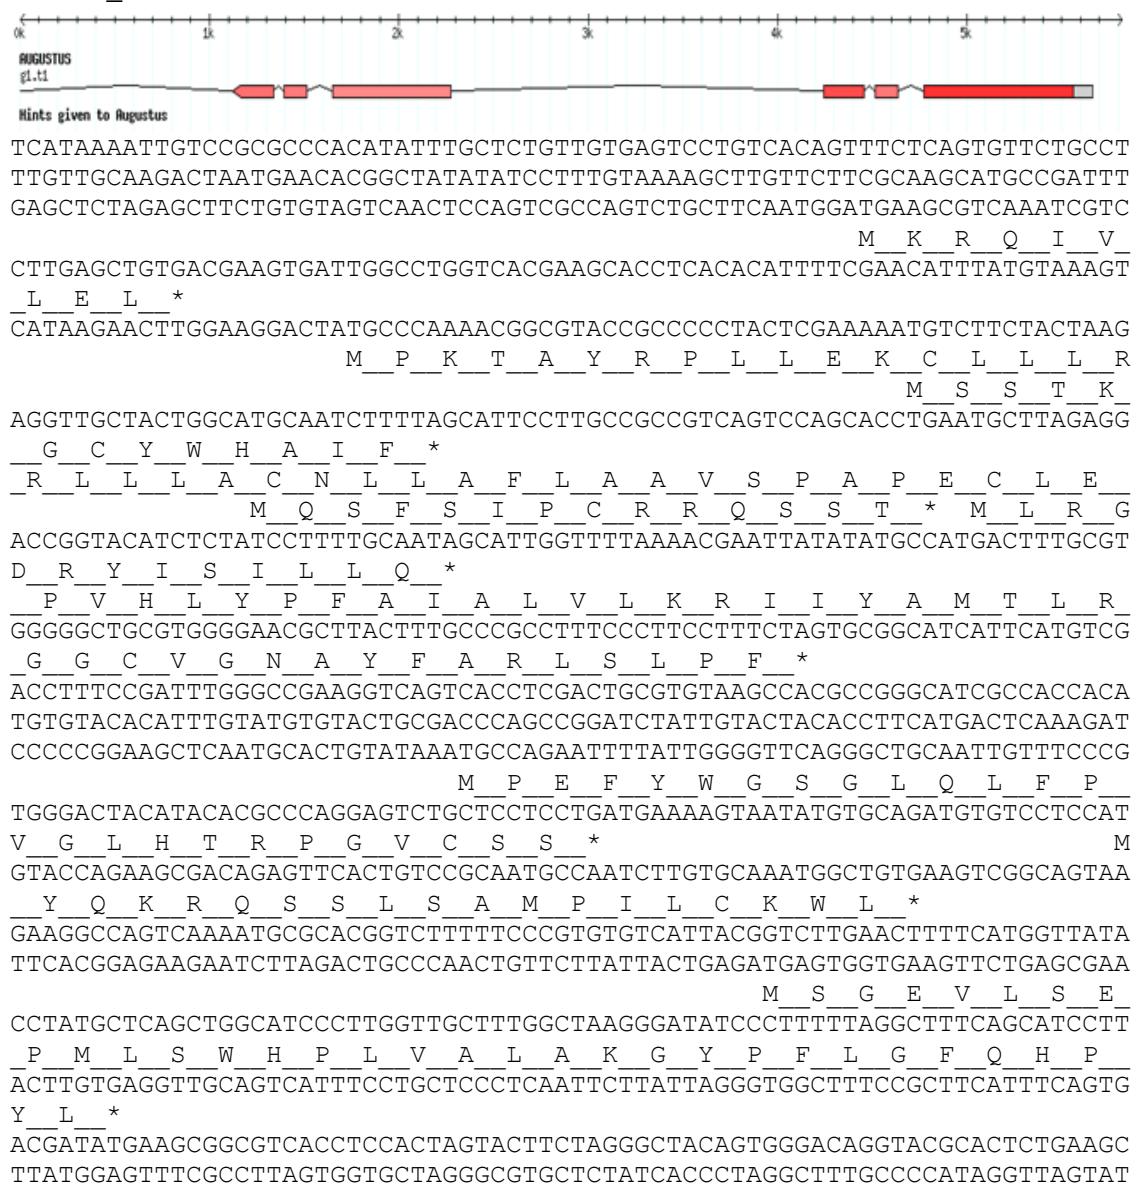
Para el cluster de sORFs 2L_16, el programa Augustus Gene Prediction predijo una estructura de 2 exones, uno de 428 pares de bases y el otro de 50 pares de bases, y un intrón de 1734 pares de bases.

Se encontró acuerdo con espectro de masas para el péptido MQLIVFSTHR con una probabilidad de $p=0.031$ y un valor E=1.77918840258577e-05; para el péptido MTDTYSGQNTSVMR con una probabilidad de $p=0.042$ y un valor E=0.000643597686829289; para el péptido ISIRLLFCTCK una probabilidad de $p=0.02$ y un valor E=0.00065656819598243; y para el péptido QLYLVLRIEYD una probabilidad de $p=0.019$ y un valor E=0.000174133872588637.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 26 sORFs. El sORF vigésimocuarto es una duplicación desplazada del segundo sORF. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 4 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_39



M_E_F_R_L_S_G_A_R_A_C_S_I_T_L_G_F_A_P_* M
 GGGTCTGACTACCATGAGGTACAGCCATCTTATTATGCGTGGTGGAGGTTCCCCACGACTTACCAAGCAATG
 _G_L_T_T_M_R_Y_S_H_L_I_M_R_G_E_V_P_H_D_L_P_A_M
 TTTCTACACGTGAAAAGTGCTCTGGTGCACTTATCAATTGTTATCGACATGAGTTGAAGCTGAGTT
 _F_L_H_V_K_S_A_L_V_H_L_S_I_L_L_S_T_*
 M_S_F_E_A_E_F
 TGGAGTAAAGGGCTATCCAAGATACTTAACCTCATTGCTGGCCTCTATGCCACATTGACAGGGCTAT
 _G_V_K_G_Y_P_K_I_L_N_F_I_A_G_L_Y_A_T_F_*
 M_P_H_F_D_R_A_I
 TGCCTTCATTCTCTGCTAGGATTAGGCTCAGGCCTACTTCCTGAACCATTGCTGGTCATATTGATGC
 _A_F_I_L_C_*
 CCAGTTGAATGATATCGCAGAGTGTTCTCATATTACCTCTGGCTATAATGACAATATCGTCAGCATA
 M_I_S_Q_S_V_S_S_Y_L_P_L_A_I_M_T_I_S_S_A_*
 GCCTTGGCAAAGTACCTCTGCGGGTCAGTCTGTCAGCAACTCGCGTACCAAGCTCCACAGGAGA
 GGCGAGAGGACACCCCTGGGAGCACCTCTGTTAGGTACTGTGGACGACTGCCCTCCTATAGTGG
 CCATGGCTCGTTAGATGCCAGTAGTGACTTGATCCATCTGCTGGTTGGCATCTAGTCCTCTTGC
 CAGGGATGCGTTGACAGCTCATGGGAGGTATTGTCGAATGCCACCTGTATGTCATAAGAACACATAAC
 M_G_G_I_V_E_C_T_L_Y_V_*
 M_H_P_V_C_L_R_R_H_I_T
 GCCACTTCCTTATGAGTCAGTGAATCCTCAATAAGGCTTTAGGTGATATAGGGCAGTATCAGTTGATC
 _P_L_P_Y_E_S_V_N_P_Q_*
 TTCCCGCCATGTAGGCATGCTCGTTCGGCGACGCTGGTCCCCATATTACGTGATGTCATTTGC
 M_L_R_S_L_A_T_P_G_A_P_Y_Y_V_M_C_I_C
 ATCACATCCAATGATGATGGTGAGTGACATCCTCTGCAGTGTTCAGCAGTGAGTGCATTTGGCGGT
 I_T_S_N_D_D_G_*
 GGGCACGCCCTCGTACCGTCAAAGTATGCCGATGCCACCACAGTCTCCTGGCTGGTCCCACATCTCTA
 M_P_M_P_Q_S_P_W_L_F_P_H_L_L
 CCACGATCGGTACACAGTCCCGCGTGAGAAATTCTGTAAGTATATAATAATTACACATGCCAG
 P_R_S_V_H_S_P_A_*
 GATACAGGCTCTAGGTCTAGAAGCCCATTGATCCAAATTACCCAGGCGTTCTCACGTACAGTCCACGT
 ATGCCCTGGTTATACCATGGTTCTGTACCAAGGCTAGCCAAAGATGTTGCTGGTGAACATCCTTGCA
 M_V_S_V_P_G_L_A_Q_D_V_A_W_*
 M_L_L_G_E_H_P_C_Q
 ATCGACGTGAGCCGTCGATTGCACTCCCTGAATGGATGTTACCTACTAACATTACCTCCA
 S_T_*
 ACAGCGGGCCACAGCTTGGCGACTGAGGAGAATTGCAATTAAAGCTTGGATCTATGAGGTTCTCGTAATC
 CCCCTGAAGCTTCTGAAGAACGCCCTCATAAAATTGTCGCGGCCACATATTGCTCTGTTGAGTCC
 TGTCACAGTTCTCAGTGTCTGCCTTGTGCAAGACTAATGAAACACGGCTATATATCCTTGTAAAAG
 CTTGTTCTCGCAAGCATGCCGATTGAGCTCTAGAGCTCTGTGAGTCAACTCCAGTCGCCAGTCTGC
 TTCAATGGATGAAGCGTCAAATCGCCTTGAGCTGTGACGAAGTGATTGGCCTGGTCACGAAGCACCTCA
 M_K_R_Q_I_V_L_E_L_*
 CACATTTGCAACATTATGTAAGTCATAAGAACTTGGAGGACTATGCCAAACGGCGTACCGCCCC
 M_P_K_T_A_Y_R_P
 CTACTCGAAAAATGTCTTACTAAGAGGTTGCTACTGGCATGCAATCTTAGCATGCCCTGGCGCCGT
 L_L_E_K_C_L_L_R_G_C_Y_W_H_A_I_F_*
 M_S_S_T_K_R_L_L_A_C_N_L_L_A_F_L_A_A_V
 M_Q_S_F_S_I_P_C_R_R
 CAGTCCAGCACCTGAATGCTTAGAGGACCGGTACATCTATCCTTGCATAGCATGGTTAAAC
 S_P_A_P_E_C_L_E_D_R_Y_I_S_I_L_L_Q_*
 Q_S_S_T_* M_L_R_G_P_V_H_L_Y_P_F_A_I_A_L_V_L_K
 GAATTATATATGCCATGACTTGCCTGGGGCTGCGTGGGGAAACGCTTACTTGCCTGCCCTTCCCTCC
 R_I_I_Y_A_M_T_L_R_G_G_C_V_G_N_A_Y_F_A_R_L_S_L_P
 TTTCTAGTGCAGCATTCATGTCACCTTCCGATTTGGGCCAGGTCAGTCACCTCGACTGCGTGT
 F_*
 AAGCCACGCCGGGCATGCCACCATGTCACACATTGTTATGTGACTGCGACCCAGCCGGATCTATT
 GTACTACACCTTCATGACTCAAAGATCCCCGGAAGCTCAATGCACTGTATAATGCCAGAATTATTATTG
 M_P_E_F_Y_W
 GGGTCAGGGCTGCAATTGTTCCCGTGGGACTACATACACGCCAGGAGTCTGCTCCTCGATGAAAA
 G_S_G_L_Q_L_F_P_V_G_L_H_T_R_P_G_V_C_S_S_*
 GTAATATGTGCAGATGTGCCTCCATGTACCAAGAGCGACAGAGTTCACTGTCCGCAATGCCAACTTGT
 M_Y_Q_K_R_Q_S_S_L_S_A_M_P_I_L_

GCAAATGGCTGTGAAGTCGGCAGTAAGAAGGCCAGTCAAAATGCGCACGGCTTTCCGTGTGCATT
 C_K_W_L_*
 ACGGTCTTGAACCTTTCATGGTTATTCACGGAGAAGAACATCTAGACTGCCTAACGCCCTGGTAGGTTT
 CCCGAAGAACAGACGTTTCTATGGTGACCAACAGGACAGAAGGGCTCGGGCCAATTAGAGGGTT
 M_V_T_N_R_T_E_G_L_G_P_N_*
 TCTTTGCCTCTTCCTGGCTAGGTTGTCCGCTAGCTCATTCGGGATGGTAGTGTCCGGGACCCA
 M_L_L_C_P_G_T_H
 CCTTATTGTGGGTTGTTGACAGCTCCTAGTTGTCTAGGGCTGTCCACTTACTACCTTAGAT
 L_I_V_G_L_L_T_A_P_S_L_S_R_A_V_L_T_L_L_T_T_L_D
 GTTATCTTAGCTTGCTGAGGCCCTTATGGCTGCTGACTATCAGACAGTATAGCAATGTCCCTGCCAC
 V_I_L_A_L_L_S_A_F_M_A_A_*
 GATAGTTCTTGCAAGATTAACCCGCACAGCGTACAATAGCACAGACTTCAGCTGAAAAATGCTGGT
 M_L_V
 GTATCTGCCATTGATTGTAGTATTCAACGTGGGCCTACACGCCAGCCCACCTCCCTCGTCGGTG
 Y_L_P_I_D_S_*
 AGGGATCCGTCTGTATACCACTTATTGCTTGTGGTTCATAGGGTGTACTTCCCCAGGGATGTCCAAC
 TGTTCTTATTACTGAGATGAGTGGTGAAGTTCTGAGCGAACCTATGCTCAGCTGGCATCCCTGGTTGCT
 M_S_G_E_V_L_S_E_P_M_L_S_W_H_P_L_V_A
 TTGGCTAAGGGATATCCCTTTAGGCTTCAGCATCCTACTTGTGAGGGTGCAGTCATTCCCTGCTCC
 L_A_K_G_Y_P_F_L_G_F_Q_H_P_Y_L_*
 CTCAATTCTTATTAGGGTGGCTTCCTCTTCATTCAATGACGATATGAAGTGGCGTCACCTCCACTAGT
 ACTTCTAGGGTGCAGTGGACAGGTACGCACTCTGAAGCTTATGGAGTTGCCTTAGTGGTCTAGGG
 M_E_F_R_L_S_G_A_R
 CGTGCTCTATCACCCCTAGGCTTGCCCCATAGGTTAGTATGGGCTGACTACCATGAGGTACAGCCATCT
 A_C_S_I_T_L_G_F_A_P_* M_G_L_T_T_M_R_Y_S_H_L
 TATTATGCGTGGTGGAGGTCCCCACGACTTACCAAGCAATGTTCTACACGTGAAAAGTGCTGGTGCAC
 I_M_R_G_E_V_P_H_D_L_P_A_M_F_L_H_V_K_S_A_L_V_H
 TTATCAATTGGTATCGACATGAGTTGAAGCTGAGTTGGAGTAAGGGCTATCCAAGATACTAA
 L_S_I_L_L_S_T_*
 M_S_F_E_A_E_F_G_V_K_G_Y_P_K_I_L_N
 CTTCATTGCTGGCCTCTATGCCACATTGACAGGGTATTGCTTCATTCTGCTAGGATTAGGCTC
 F_I_A_G_L_Y_A_T_F_*
 M_P_H_F_D_R_A_I_A_F_I_L_C_*
 AGGCCTACTCCTGAACCATTGCTGGTATATTGATGCCAGTTGAATGATATCGCAGAGTGTTCCT
 M_I_S_Q_S_V_S
 CATATTACCTCTGGCTATAATGACAATATCGTCAGCATAGCCTGGCAAAGTATACCTCTGGGGTCAG
 S_Y_L_P_L_A_I_M_T_I_S_S_A_*
 TCTGTCCAGCAACTCGCGTACAGCAAGCTCCACAGGAGAGGCGAGAGGACACCCCTGGGAGCAACCT
 CTTGTGGTAGGTACTGTGGACGACTGCCCTCTATAGTGGCATGGCTCGTTAGATGCCAGTAGTGA
 TGATCCATCTGGTTGCATCTAGCCTCTTGCAGGGATGCGTGCACAGCTCATGGGAGGT
 M_G_G
 ATTGTCGAATGCACCCGTATGTCTAAGAAGGCACATAACGCCACTCCTATGAGTCAGTGAATCCTCA
 I_V_E_C_T_L_Y_V_*
 M_H_P_V_C_L_R_R_H_I_T_P_L_P_Y_E_S_V_N_P_Q
 ATAAGGCTTCAGGTGATATAGGGCAGTATCAGTTGATCTCCCGCCATGTCAGGATGCTGGTTCGTT
 * M_L_R_S_L
 GGCGACGCCCTGGTGGCCCATATTACGTGATGTGCATTGACATCACATCCAATGATGATGGTTGAGTC
 A_T_P_G_A_P_Y_Y_V_M_C_I_C_I_T_S_N_D_D_G_*
 CCTCTTGCAAGTGGTCAAGCCAGTCAGTGAATTGGCGGTGGCACGCCCTCGTACCGTCAAAGTATGCC
 M_P
 GATGCCACACAGTCTCCTGGCTGTTCCCACATCTTACACAGATCGGTACACAGTCCCCTGGTGA
 M_P_P_Q_S_P_W_L_F_P_H_L_L_P_R_S_V_H_S_P_A_*
 ATTCTGTAAGTATAATAATTAAACTACAACATGCCAGGATAACAGGCTTAGGTCTAGAACGCCATTG
 ATCCCAAATTACCCAGGCCTCTCACGTACAGTCCACGTATGCCCTGGTTATACCATGGTTCTGTACC
 M_V_S_V_P
 AGGGCTAGCCAAGATGTTGCTGGTGAACATCCTGCCAATCGACGTGAGCCCGTCAATTGCA
 G_L_A_Q_D_V_A_W_*
 M_L_L_G_E_H_P_C_Q_S_T_*
 CCCTTGAATGGATGTTTACCTACTTAACATTACCCCTCCAACAGCGGGCCACAGCTGGCGACTGAGGA
 GAATTGCAATTAAAGCTTGGATCTATGAGGTTCTCGTAATCCCCCTGAAGCTTCTGAAGAACGCCATT
 AAAATTGTCGCCACATATTGCTCTGTTGAGTCCTGTCACAGTTCTCAGTGTGCTGCCTTGT

TGCAAGACTAATGAACACGGCTATATCCTTGAAAGCTTCTCGCAAGCATGCCGATTGAGC
 TCTAGAGCTTCTGTAGTCACCCAGTCGCCAGTCCTCAATGGATGAAGCGTAAATCGTCTTG
 M_K_R_Q_I_V_L
 AGCTGTGACGAAGTGATTGGCCTGGTCACGAAGCACCTCACACATTTGAACATTATGTAAGTCATA
 E_L *

AGAACTTCCAAGGACTATGCCAAAACGGCGTACCGCCCCCTACTCGAAAAATGTCTCTACTAAGAGGT
 M_P_K_T_A_Y_R_P_L_L_E_K_C_L_L_L_R_G
 M_S_S_T_K_R

TGCTACTGGCATGCAATCTTAGCATTCCTGCCCGTCAGTCCAGCACCTGAATGCTTAGAGGACCG
 C_Y_W_H_A_I_F *

L_L_L_A_C_N_L_L_A_F_L_A_A_V_S_P_A_P_E_C_L_E_D_R
 M_Q_S_F_S_I_P_C_R_R_Q_S_S_T_* M_L_R_G_P

GTACATCTCTATCCTTTGCAATAGCATTGGTTAAAACGAATTATATGCCATGACTTGCCTGGGG
 Y_I_S_I_L_L_Q *

V_H_L_Y_P_F_A_I_A_L_V_L_K_R_I_I_Y_A_M_T_L_R_G
 GCTCGTGGGAACGCTTACTTGCCCGCCTTCCTCCTTAGTGCACATTCATGTCGACCT
 G_C_V_G_N_A_Y_F_A_R_L_S_L_P_F *

TTCCGATTGGGCCAAGGTCACTGCACCTCGACTCGGTAAAGCCACGCCGGCATGCCACCATGTG
 TACACATTGTATGTACTGCGACCCAGCCGGATCTATTGACTACACCTTCATGACTCAAAGATCCCC
 CGGAAGCTCAATGCACTGTATAAATGCCAGAATTATTGGGGTTCAGGGCTGCAATTGTTCCGTGGG
 M_P_E_F_Y_W_G_S_G_L_Q_L_F_P_V_G

ACTACATACACGCCAGGAGTCTGCTCCTCTGATGAAAAGTAATATGTGCAGATGTGCTCCATGTAC
 L_H_T_R_P_G_V_C_S_S * M_Y_Q_K_R_Q_S_S_L_S_A_M
 CAGAACGGACAGAGTTCACTGTCGCAATGCCAATCTGTGCAAATGGCTGTGAAGTCGGCAGTAAGAAG
 P_I_L_C_K_W_L *

GCCAGTCAAAATGCGCACGGCTTTCCGTGTCAATTACGGCTTGAACCTTCATGGTTATATTCA
 CGGAGAAGAATCTTAGACTGCCTAAGCCCTGGTAGGTTCCGGAAGAACAGACGTTCTATGGT
 M_V

GACCAACAGGACAGAAGGGCTCGGGCCAATTAGAGGGTTCTTGCCCTTCCCTGGCTAGGTTGTCCG
 T_N_R_T_E_G_L_G_P_N *

CTAGCTCATTCGGGATGTTGTTGCTCCGGACCCACCTTATTGTTGACAGCTCCTAG
 M_L_L_C_P_G_T_H_L_I_V_G_L_L_T_A_P_S
 TTTGTCTAGGGCTGTCCTCACTTACTACCTTAGATGTTATCTTAGCTTGCTGAGCGCCTTATG
 L_S_R_A_V_L_T_L_T_L_D_V_I_L_A_L_L_S_A_F_M
 GCTGTTGACTATCAGACAGTATAGCAATGTCCTGCCACGATAGTTCTTGCAAGATTAACCGCAC
 A_A *

AGCGTACAATAGCACAGACTTCAGCTTGAAGGAAATGCTGGTGTATCTGCCATTGATTCGTAGTTCAA
 M_L_V_Y_L_P_I_D_S *

CGTGGGCCTACACGCCAGCCACTCCCTCGCGTGAGGGATCCGTGTATACCAACTTTATTGCT
 TGTGGTTCATAGGGTGTACTTCCCCAGGGATGTCAAATGTTCTTACTGAGATGAGTGGTGAAGT
 M_S_G_E_V

TCTGAGCGAACCTATGCTCAGCTGGCATCCCTGGTTGCTTGGCTAAGGGATATCCCTTTAGGCTT
 L_S_E_P_M_L_S_W_H_P_L_V_A_L_A_K_G_Y_P_F_L_G_F
 CAGCATCCTACTTGTGAGGTTGCAGTCATTGCTCCCTCAATTCTTATTAGGGTGGCTTCCTCTT
 Q_H_P_Y_L *

CATTCAATGACGATATGAAGTGGCGTCACCTCCACTAGTACTCTAGGGTTGCAGTGGACAGGTACGC
 ACTCTGAAGCTTATGGAGTTGCCTTAGTGGCTAGGGCGTCTATCACCCATTGCTTGGCCAT
 M_E_F_R_L_S_G_A_R_A_C_S_I_T_L_G_F_A_P
 AGGTTAGTATGGGCTGACTACCATGAGGTACAGCCATCTTATTATGCGTGGTGAGGGTCCCGACTT
 * M_G_L_T_T_M_R_Y_S_H_L_I_M_R_G_E_V_P_H_D_L
 ACCAGCAATGTTCTACACGTGAAAGTGTCTGGTCACTTATCAATTGTTATGACATGAGTTTG
 P_A_M_F_L_H_V_K_S_A_L_V_H_L_S_I_L_L_S_T * M_S_F
 AAGCTGAGTTGGAGTAAAGGGCTATCCAAGATACTTAACCTCATTGCTGGCTCTATGCCACATTG
 E_A_E_F_G_V_K_G_Y_P_K_I_L_N_F_I_A_G_L_Y_A_T_F * M_P_H_F
 ACAGGGCTATTGCCCTCATTCTGCTAGGATTAGGCTCAGGCCTACTCCTGAACCATTGCTGGTC
 D_R_A_I_A_F_I_L_C *

ATATTGATGCCAGGTGAATGATATCGCAGAGTGTTCCTCATATTACCTCTGGCTATAATGACAATAT
 M_I_S_Q_S_V_S_S_Y_L_P_L_A_I_M_T_I
 CGTCAGCATAGCCTGGCAAAGTATACCTCTGCGGGTCAGTGTCCAGCAACTCGCGTACCAAGCT

S _ S _ A _ *
 CCACAGGAGAGGCAGAGGACACCCCTGGGAGCAACCTCTTGTGGTAGGTACTGTGGACGACTGCCCT
 CCTATAGTGGCATGGCTCGCTTAGATGCCAGTAGTGACTTGATCCATCTGCTGGTTGTCATCTAGTC
 CTCTTCTGCCAGGGATCGTTGACAGCTCATGGGAGGTATTGTCGAATGCACCCGTATGTCTAAGAA
 M _ G _ G _ I _ V _ E _ C _ T _ L _ Y _ V _ *
 M _ H _ P _ V _ C _ L _ R _
 GGCACATAACGCCACTTCCTTATGAGTCAGTGAATCCTCAATAAGGCTTCAGGTGATATAAGGCAGTA
 R _ H _ I _ T _ P _ L _ P _ Y _ E _ S _ V _ N _ P _ Q _ *
 TCAGTTGATCTTCCGCCATGTAGGCATGCTCGTTGGCGACGCCCTGGTGCCCCATATTACGTGAT
 M _ L _ R _ S _ L _ A _ T _ P _ G _ A _ P _ Y _ Y _ V _ M
 GTGCATTGTCATCACATCCAATGATGGTTGAGTGCATCCTCTTGCACTGTCAGTGGTCAAGCAGTGCAGTGAT
 C _ I _ C _ I _ T _ S _ N _ D _ D _ G _ *
 TTCGGGGGGTGGGCACGCCCTCGTCAACCGTCAAAGTATGCCGATGCCACACAGTCTCCTGGCTGTTCCC
 M _ P _ M _ P _ P _ Q _ S _ P _ W _ L _ F _ P
 ACATCTTCTACCACGATCGGTACACAGTCCC CGTGAGAAATTCTGTAAGTATATAATAATTAACTAC
 H _ L _ L _ P _ R _ S _ V _ H _ S _ P _ A _ *
 AACATGCCAGGATACAGGCTCTAGGTCTAGAAGCCCATTGATCCCAAATTACCCAGGGCGTCTTCACGTA
 CAGTCCACGTATGCCCTGGTTATACCATGGTTCTGTACCAAGGGCTAGCCCAAGATGTTGCTGGTGAAC
 M _ P _ W _ L _ Y _ H _ G _ F _ C _ T _ R _ A _ S _ P _ R _ C _ C _ L _ V _ N _
 M _ V _ S _ V _ P _ G _ L _ A _ Q _ D _ V _ A _ W _ *
 M _ L _ L _ G _ E _
 ATCCTGCCAGCACAGCTCAGGCCGCCTGGCGCGATGTATGTTACCTGAGCTATCCCTGTACTATCCC
 I _ L _ A _ S _ T _ A _ Q _ A _ A _ L _ A _ R _ C _ M _ F _ T _ *
 H _ P _ C _ Q _ H _ S _ S _ G _ R _ L _ G _ A _ M _ Y _ V _ Y _ L _ S _ Y _ P _ C _ T _ I _ P
 TGTATGATCGGCTCCATCGTCGGCGTTACTAATCTGGAGATGCCCGATCACTATCCGCCGGTACCGCTT
 V _ *
 M _ I _ G _ S _ I _ V _ G _ V _ T _ N _ L _ E _ M _ P _ R _ S _ L _ S _ A _ G _ T _ A _
 CTTCTTACTTAGCAGGTCTAGTTCCATGACTAGGTCTGAGAGGATATCGGGGTCTGATCCTCCATCTC
 S _ S _ L _ L _ S _ R _ S _ S _ S _ M _ T _ R _ S _ *
 GATGACGGTCGATCGAGATCCATATCCGCAAGAACCTCGCTGGA
 M _ T _ V _ A _ S _ R _ S _ I _ S _ S _ A _ R _ T _ S _ L _ G _ A _ *

Para el cluster de sORFs 2L_39, el programa Augustus Gene Prediction predijo una estructura de 6 exones, uno de 215 pares de bases, el segundo de 122 pares de bases, el tercero de 623 pares de bases, el cuarto de 215 pares de bases, el quinto de 122 pares de bases y el sexto de 895 pares de bases, y 5 intrones, uno de 55 pares de bases, el segundo de 135 pares de bases, el tercero de 1970 pares de bases, el cuarto de 55 pares de bases y el quinto de 135 pares de bases.

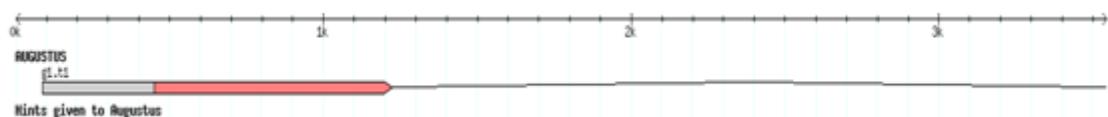
Se encontró acuerdo con espectro de masas para el péptido QSFSIPCRR con una probabilidad de $p=0.028$ y un valor $E=0.000572181997750584$; para el péptido LLCPGTHLIVGLLTAPSLSR con una probabilidad de $p=0.058$ y un valor $E=1.70994459689005e-06$; para el péptido LLLACNLLAFLAAVSPAPECLEDRL una probabilidad de $p=0.02$ y un valor $E=0.000683845203177432$; para el péptido GEVPHDLPAMFLHVK una probabilidad de $p=0.086$ y un valor $E=0.000419547838544714$; para el péptido RQIVLEL una probabilidad de $p=0.006$ y un valor $E=0.000419717048509459$; para el péptido TAYRPLLEKCLLLR una probabilidad de $p=0.044$ y un valor $E=0.000307576662455124$; para el péptido CLLLRGCYWHAIF una probabilidad de $p=0.056$ y un valor $E=0.000424692340298027$; y para el péptido MLLGEHPCQHSSGR una probabilidad de $p=0.098$ y un valor $E=0.000876828754197293$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 65 sORFs. Se pueden observar varias repeticiones. No se observa presencia de ESTs, con lo cual no se halla evidencia de

transcripción. La probable traducción se basa en la presencia en bases de datos de 8 péptidos definidos por espectrometría de masas que cumplían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_63



```

TTCGGAATATGTATTACATTCAATATTATTATCAGCGTCAAATTAGCGTCGGTAAGTTAGCGTCGTT
M Y L H S I L F I S V K L A S V S * 
TTTACATCCGTCGTCTAAACTGTGCTAGACAACAGCGAAGATAACATACATGTATATGTCGGAGCGC
M Y M S E R 
GACTCTCGCATTCCAGAAATTCCCTCTGTGATTCATATTCTGATGAAATTGTAATATTGCGGTAAAAT
D S S H S R N S F C D F I F * 
TCTGTCGAGCGCTCGGGCAGAGGCACGAACAGCCTCTGCAGCTGAGTGAGGTCCGATCGAGTGGTCATAA
ATAGTGTGTTAGAGAGAGATGACAATGTGGCACACGCCAGTGTGTATAGCCATTAGAGAATATGATGAAG
M T M W H T P V C I A I R E Y D E 
M M K 
AAGGGACATGTAAGAAGATCCCTCAGTGAAGTTGACTGCTGACGTCGATCGGAACCTGCTGCGCTGAC
E G T C K K I P S V K F D C * 
K G H V R R S L Q * 
GTACAAAATCGCGAAGTGAATAATAATGGATGAGACTCCTGTTGCCGACATCAGAAGTGGGATCG
M R L L F R R H Q K W D R 
CCTTCGCCACAAGAGACCAGACCTGATCAGTATATGGCTGCGTGGAGGCACAAACCGTAACCTCATGG
L R H K R P D L I S I W L R W R H K T V T S W 
AGATAATAAGAACCATGCACGCACCGAGAGCATCGCGTCAAATGAAAAGTCCTGCACGTCGCACTGCC
R * 
M K S P C T S H C 
AAAATTCTGCGCTGACAGCGCTGGAGCAGATCCATCTGCATGGTGCACCCACCGTGGATTAACTTTGCA
Q N S A L T A L E Q I H L H G A P P W I * 
M V H H R G F N L C 
GATAATGCGCTTGTAGGCAGTGCACTCGTAATAGCGTTAAGCAAAGCATTAGAAGGCAGTGCATCGCAAT
R * 
M 
GGCTGTCGAGATATGCTCGCTGGCATACGTGCCAGTTAAAGAACTGTTACAGCGATTGCT
A V A D M L R W H H V A A V * 
AGGAATGGAGACGTCGGCTGCTATTGATGAACGTTTGAGAACGGACGTCCAACACCTGGAGAGAGCTT
GCCAGTATGGAAGTCGCATTGTCACCTGTTGCTGCTAAGTGAAGGCCAAGGATTGGAGGGAGATTG
M E V A L S P C C C L S G R P R I W R R L 
CGGTTTGGTAGCGTGGCTACATGGCACAAATCGATAATAAGTTGCTGTGGGTGTTACGACTAA
R F R * 
TGTGGCTACCGCAATGAGCTTCAGCAACAACACTGCAAGCTTACGCCTCAAGAACGTAACAACGAAGAT
M W L R A M S F S N N C K L T P S R N V T T K M 
GATTCTGGCCCAGAAAAAAAGTTAAGAATGCAGTTGCAGACCATGTGCCATTGTTGGAAAGCTGGCC
I L A Q K K S * 
ACAAATTGCGCAATGCCGTGCTGAAAGGAAGGTACATCAAACACAAAAGGAAGAAACTACAGCGAAAG
M P C S K G R Y I K H K R K K L Q R K 
CAACACGCCTGGTTAAAAGATCGTCAACATAAAATGTTAAATGCGACGAAATGGGACATGTGGCG
Q H A W V K R S F E H K M F * M R R N G T C G 
M W R 
TCTGTATGTCCAAAGGCCACAACAAATACATCGAAAAGCGAGTTGACGTGTGCGAAACTAAGTGAGCCA
V C M S Q R P Q I H R K A S * 
L Y V P K A T T N T S K S E L T C A K L S E P 

```

AGTGGACTGTGTTTCATTGGGTGAGCCCTTCCATTTTTTGATTGGACGCCAATGTTCTT
 S_G_L_C_F_S_I_G_*
 AATAAAGGATAAATTAAAGTAACAAATTGGCTGGCAAGAGAATTAATAACCTAGTTAGGAAATT
 GGTGACAATGTAGTTAAGAGCCACTTGCAAATACTATAAACAGTCCAATGTCAATTGAATTAGAAA
 TTTGTTCATGTTAGTGGACAATTTAAAGTACGACATAATGATTGGCAAGACATATTAGAGCT
 TGGTTCGTTTATTGATTAATCTAATAAAATTAGCATGTACAAATCCAAAGTTATCAATGCCGTTCAA
 M_P_F_K
 AATAATGCACATGAGAATAGTTGGAAAAACTTTGACATCAATAACAGAAGTAAGCGATAATGATAAT
 I_M_H_M_R_I_V_W_K_N_F_L_T_S_I_Q_K_*
 GTAAATTAAAGAAATATATTGGAAAAGTATGCCGATAGTTCTGTAACGGGATACCAAATAAGGCGCATTG
 GAAATTCTTTAAGTAATAAAATAAAAGTGTCAAGGGGCCATATCGACTCAGTTCCATTGCTACT
 GATTTGGATCAAATAGATCGTTGCGGTGTTAGACATGGCCAGCG
 M_A_S
 GATTCTATAGAAGAGTCAGTATGTCCTTAGAGCTCCAGTCGCATCATAGGGATCAAGGCAGAA
 G_F_Y_R_R_V_K_Y_V_F_P_*
 GCTTGTCAAGCAACAAGTCCGTGAGCTTGTCAACAAACAGGATTGAGTTGTTCAATAGCTACAGA
 TGCCAGCAGCAAATGGGCAGGTTGAAAACAAATGAGCGTACAAGCAAGGAAAACATGCGAAAGGATGT
 M_P_A_E_Q_M_G_R_L_K_T_N_E_R_T_S_K_E_N_M_R_K_D_V
 M_S_V_Q_A_R_K_T_C_E_R_M
 AGAGTAGTCGGTATGAGGTATGTTAAGTGAGAAGTATCATCGAGTGATTAATGTTAGATGGTCA
 E_*
 TCGACACAATTGAAGTCGTTAGTTATCAAGCGAACATATAAATTCGCATGAATGTAATGGTACTCC
 M_N_V_M_V_T_P
 CAACAGAGAAAAGAGTTGAAGGGATGGCACTAGTGAACGTGCATCTGTGCCCCAAGAGAGAAAAGAGTTA
 N_R_E_K_S_* M_A_L_V_N_H_L_C_P_K_R_E_K_S_L
 AAGATGGCACTAGTGTGCATCTGTGCCCCAAGAAAGGAAACATTGGCGAACGTTATGAATAGAAT
 K_M_A_L_V_I_V_H_L_C_P_K_K_G_N_I_W_R_T_L_*
 GGCGTGTGACCGCACTATAACAGCTAACTCGCAGGGACGAGAAGTGTATGGCGGGGGTCAAGTGATGAT
 GACTGCACTATAACAGCTAACTCGCAGGGACGAGAAGTGTATGGCGGGGGTCAAGTGATGACTGCA
 CTATAACAGCTAACTCGCAGGGACGAGAAGTGTATGGCGGGGGTCAAGAGATTGGGTGAGAGAAGACACGCCAA
 AGCTAACTCGCAGGGACGAGAAGTGTATGGCGGGGGTCAAGAGATTGGGTGAGAGAAGACACGCCAA
 M_A_G_V_K_R_L_G_V_R_E_D_T_P
 TGTTATTATGAGAAATTAAAGTCATGGAAAATGTAATAGTTGAAGTGTGATATGAAATTGGAGATG
 M_L_L_* M_E_N_V_N_S_L_K_F_*
 TCTTGTAAAAGAAAATCAGTCATGAGATGAATTGTCATTAATAATTACTGATTATTACTTGTGTC
 ATTAATTGTTCTTAAGTTGACGAAGTTGTGACTTGGACTTGATTGGGATTAGGCACACGAGGACGT
 GTGAAAGGTAGGAAGGCCGTGCGAGCGCAGCTTCGACATTCCAGAAATTCTCTGTGATTCATA
 TTCTGATGAAATTGTAATATTGCGTAAATTCTGAGCGCTGCGAGGACAGGAACAGCCTCTGC
 AGCTGAGTGAGGTCCGATCGAGTGGTCATAAATAGTGTGTTAGAGAGAGATGACAATGTGGCACACGTCA
 M_T_M_W_H_T_S
 GTGTGTATGCCATTAGAGAATATGATGAAGAAGGGACATGTAAGAAGATCCCTCAGTGAAGTTGACT
 V_C_I_A_I_R_E_Y_D_E_E_G_T_C_K_K_I_P_S_V_K_F_D
 M_M_K_K_G_H_V_R_R_S_L_Q_*
 GCTGACGTCGATCGGAACCTGCTGCGCTGACGTACAAATCGCGAAGTGAATAATAATATGGATGAGAC
 C_* M_D_E_T
 M_R
 TCCTGTTGCCGACATATATAAGAAAATTGTCTCTCAAAATTGTGAAAACAAATTGTAATCCAAC
 P_V_S_P_T_Y_I_R_K_I_V_F_S_K_I_V_K_N_K_L_*
 L_L_F_R_R_H_I_*
 TTTTACATAAAATAATAAAAGTAAATTGTTAAGGTACCGTACAACCTGGAACAGGTTCTGTGA
 CGCAAGTAATTAAATATTGTTAGTTATCGTCGGAATCTGTATAT

Para la región genómica 2L_63, el programa Augustus Gene Prediction predijo una estructura compuesta por un exón de 1137 pares de bases.

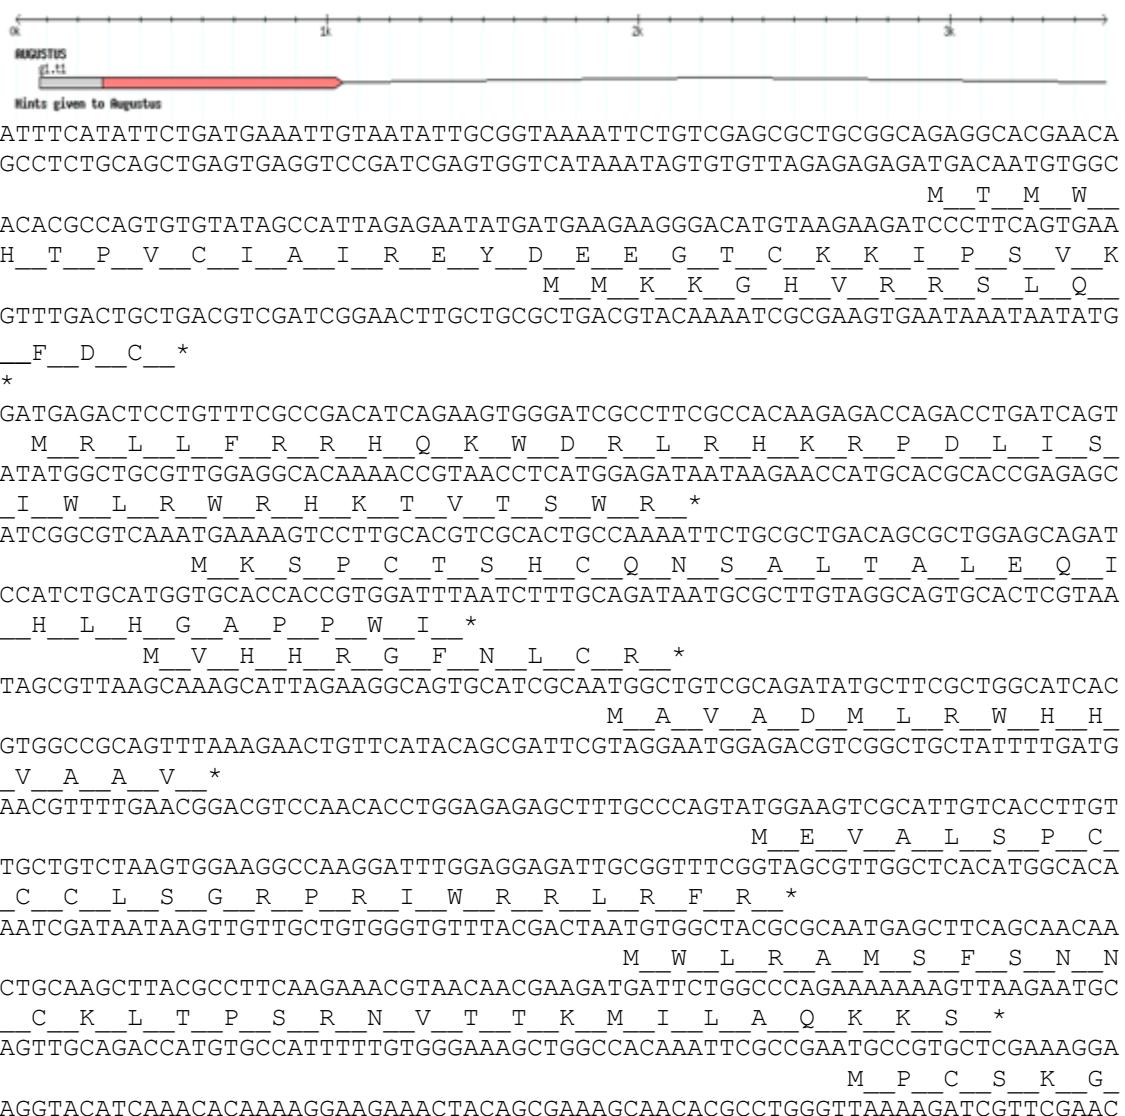
Se encontró acuerdo con espectros de masas para el péptido EYDEEGTCKK con una probabilidad de $p=0.001$ y un valor $E=5.80894615997063e-05$; para el péptido MYLHSILFISVK con una probabilidad de $p=0.069$ y un valor

E=0.000404532766085626; para el péptido MALVIVHLCPK con una probabilidad de p=0.031y un valor E=0.000313099870333286.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 25 sORFs. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 3 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo (E < 0,001) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_75



R Y I K H K R K L Q R K Q H A W V K R S F E
ATAAAATGTTAAATGCGACGAAATGGGACATGTGGCGTCTGTATGTC
H K M F * M R R N G T C G V C M S Q R P Q Q I H
M W R L Y V P K A T T N T
TCGAAAAGCGAGTTGACGTGCGAAACTAAGTGAGCCAAGTGGACTGTGTTTC
R K A S *
S K S E L T C A K L S E P S G L C F S I G *
TTTCCATTTCGATTGCGACGCCGAATGTTCTTAATAAAGGATAATTAGTAACA
GGCAAGAGAATTAATAAACCTAGTTAGGAAATTGGTGACAATGTAGTTAGAGC
TACTATAAACAGTCAAATGTCTCAATTGAATTAGAAATTGTTCATGTTAGTG
AAAGTACGACATAATGATTGCCAAGACATATTAGAGCTTGGTTCGTTATTGAT
TTAGCATGTACAAATCCAAAGTTATCAATGCCGTTCAAATAATGCACATG
M P F K I M H M R I V W K N
TTTTGACATCAATACAGAAGTAAGCGATAATGATAATGTAAGAAATATGG
F L T S I Q K *
CGATAGTTCTGTAAGTGGGATACCAAAATAAGGCGCATTGAAATTGTTAGTA
TTCAAGGGCGCCCATATCGACTCAGTTCCATTGCTACTGATTG
GGTAAATATTTTCATTTGTTAGACATGCCAGCGGATTCTATAGAAGAGTC
M A S G F Y R R V K Y V F P
TTAGAGCTCCCAGTCGCATCATAGTGGATCAAGGCAGAAGCTTGT
CAGCAACAAGTCCGTGAGCTTTG
TTCAACAAACAGGATTGAGTTGTTCAATAGCTACAGATGCCAGCAG
M P A E Q M G R L K T
AAATGAGCGTACAAGCAAGGAAAACATGCGAAAGGATGTAGAGTAG
N E R T S K E N M R K D V E *
M S V Q A R K T C E R M *
TGAGAAGTATCATCGAGTGAATGTACTAGATGGTCA
CGAACATATAATATTGCATGAATGTAATGGTCA
M A L
M N V M V T P N R E K S *
GTGAACGTGCATCTGTG
CCAAGAAAGGAAACATTGGCGAACGTTATGAATAGAATGGCGTGT
P K K G N I W R T L *
CAGGGACGAGAAGTGT
GAGAAGTGT
GTTATGGCGGGGTCAAGTGA
M
CGGGGGTCAAGAGATTGGGTGT
AAGGACATGTAAGAAGATCC
TGAAATAGTTGAAGTTTG
GTAAATAGTTGAAGT
TGTAAATAGTTGAAGT
V N S L K F *
AATTGTC
GACTTGGACTTG
GACTCTCGC
TCTGTG
TCTGTGAG
ATAGTGT
M T M W H T S V C I A I R E Y D E
AAGGGACATGTAAGAAGATCC
E G T C K K I P S V K F D C *
GTACAAAATCGCGAAGTGA
M D E T P V S P T Y I R K I
M R L L F R R H I *
GTCTTCT
TCTTTAAGGTACCGTACA
GAATCTTG
GTTTCTGGCGCG
TC
F S G A *
M S V L L N D R S L T D P I S L
TC

—C—*

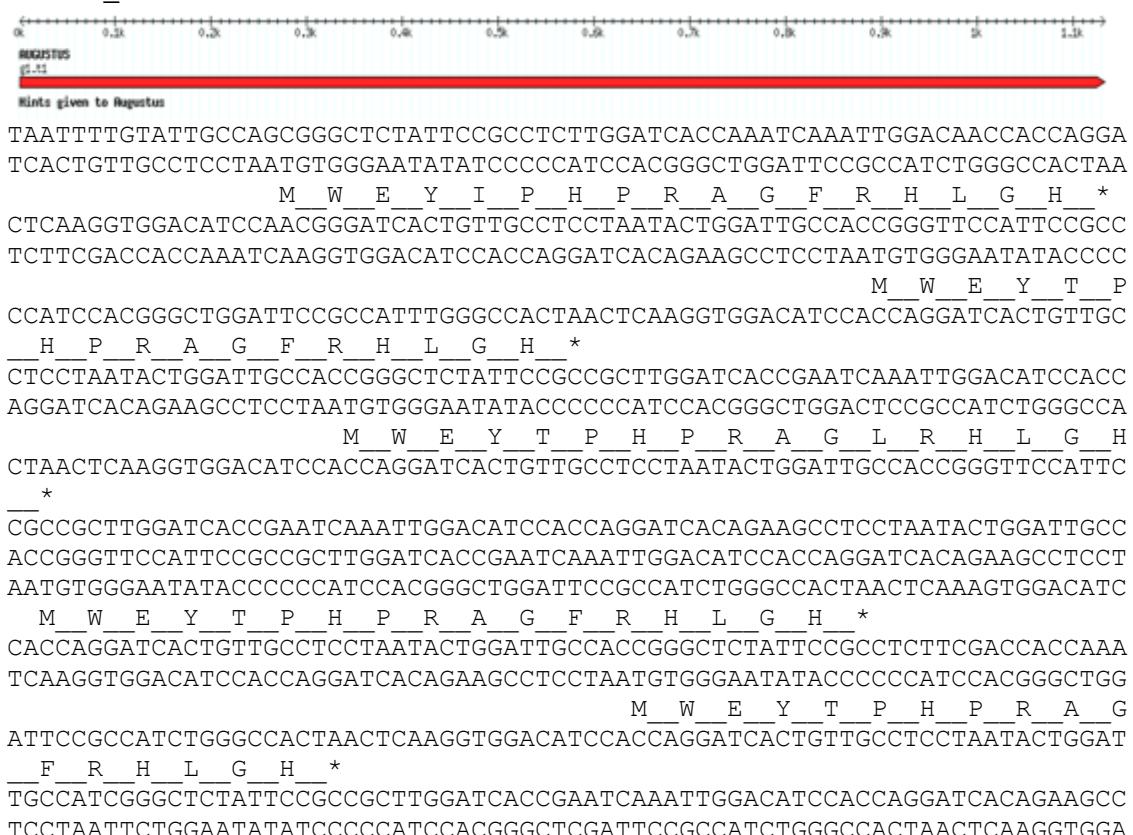
Para el gen 2L_75, el programa Augustus Gene Prediction predijo una estructura compuesta por 1 exón de 976 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido EYDEEGTCKK con una probabilidad de $p=0.001$ y un valor $E=5.80894615997063e-05$; para el péptido MALVIVHLCPK con una probabilidad de $p=0.031$ y un valor $E=0.000313099870333286$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 24 sORFs. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 2 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_96



CATCCACCAGGATCACTGTTGCCTCCTAATACTGGATTGCCATGGGCTCTATTCCGCCGCTGGATCAC
CGAATCAAATTGGACATCCACCAAGGA

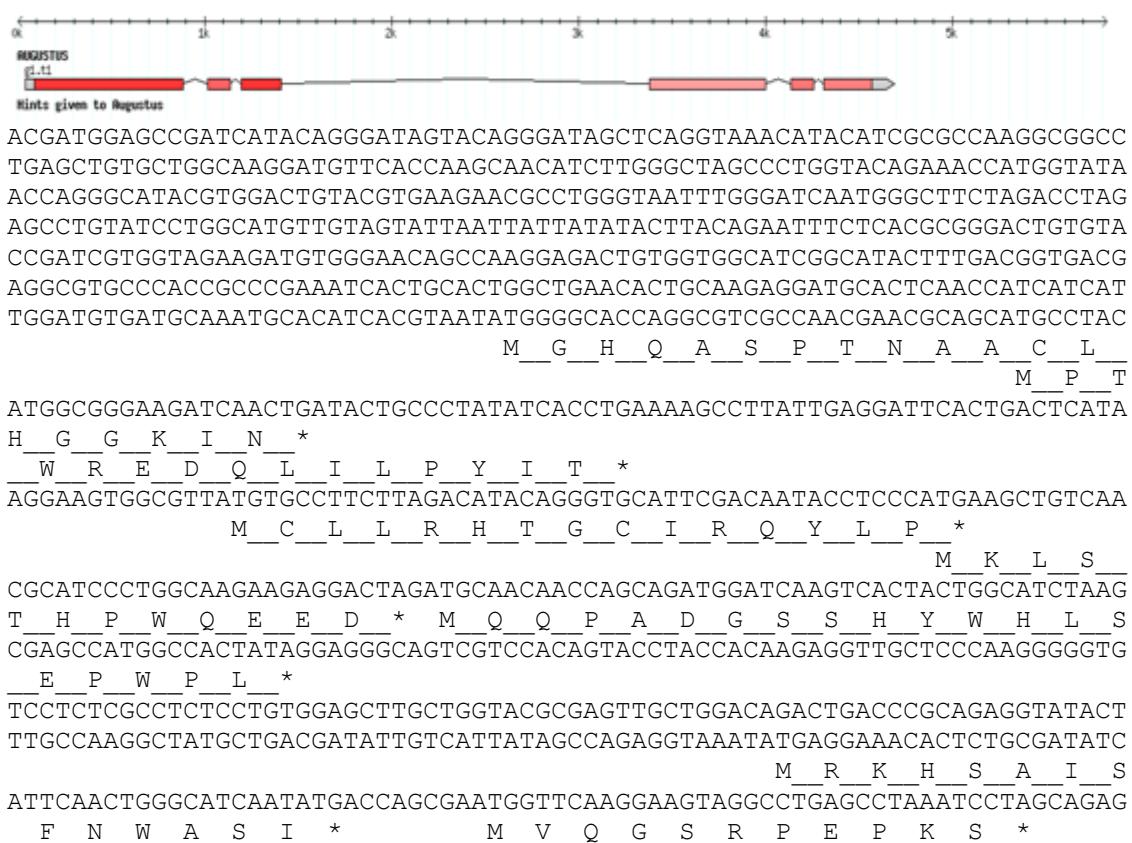
Para la región genómica 2L_96, el programa Augustus Gene Prediction predijo una estructura compuesta por 1 exón de 1132 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido WEYTPHPRAGFR con una probabilidad de $p=0.053$ y un valor $E=0.0008127839200649$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 5 sORFs. Se pueden observar repeticiones en tandem y desplazadas. Los sORFs cuarto y quinto son duplicaciones idénticas del segundo sORF. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de un péptido definido por espectrometría de masas que cumpliría con los requisitos mínimos establecidos en este trabajo ($E < 0.001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_105



AATGAAGGCAATAGCCCTGTCAAAATGTGGCATAGAGGCCAGCAATGAAGTTAAGTATCTTGGGATAGCC
 CTTTAACCAAACACTCAGCTCAAAACTCATGTCGATAACAAAATTGATAAGTGCACCAGAGCACTTTCA
 M_S_I_T_K_L_I_S_A_P_E_H_F_S
 CGTAGAAACATTGCTGGTAAGTCGTGGGAAACCTCACCGCATAATAAGATGGCTGTACCTCATGGT
 R_V_E_T_L_L_V_S_R_G_E_P_H_H_A_* M_A_V_P_H_G
 AGTCAGACCCATACTAACCTATGGGGCAAAGCCTAGGGTGATAGAGCACGCCCTAGCACCACTAAGGC
 S_Q_T_H_T_N_L_W_G_K_A_*
 AACTCCATAAGCTTCAGAGTGCACCTGTCCCAGTCAACCCCTAGAAGTACTAGTGGAGGTGACGCCAC
 TTCATATCGTCATTGAAATGAAGAGGAAAGCCACCTAATAAGAATTGAGGGAGCAGGAAATGACTGCAA
 M_T_A
 CCTCACAAAGTAAGGATGCTGAAAGCTAAAAAGGGATATCCCTAGCCAAAGCAACCAAGGGATGCCAGC
 T_S_Q_V_R_M_L_K_A_*
 TGAGCATAGGTTCGCTCAGAACCTCACCACTCATCTCAGTAATAAGAACAGTTGGACATCCCTGGGAAA
 GTACACCCTATGAAACCACAAGCAATAAAGTGGTACAGACGGATCCCTCACCGACAGGGAAAGTGGC
 TGGCGTTGAGGCCCCACGGTGAATACTACGAATCAATGGCAGATACACCAGCATTTCAAGCTGA
 AGTCTGTGCTATTGTACGCTGTGGAGTTAATCTGCAAAGAAACTATCGTGGCAGGGACATTGCTATA
 CTGTCTGATAGTCAAGCAGCCATAAAGGCCTCAGCAAAGCTAAGATAACATCTAAGGTAGTAAGTAAAG
 TGAGGACAGCCCTAGACAAACTAGGAGCTGTCAACAAACCCACAATAAGGTGGGCCCCGGACACAACAA
 CATCCCGGAAATGAGCTAGCGGACAACCTAGCCAGGAAAGAGGCAAAGAAACCTCTAATTGGGCCGA
 GCCCTCTGTCCTGTTGGTACCATAGAGAAAAACGTCGTTCTCCGGGAAACCTACCGAGGCTTAGG
 CAGTCTAAGATTCTCTCGTGAATATAACCATGAAAGTTCAAGACCGTAATGACACACAGGGAAAAAGA
 CCGTGCGCATTTGACTGGCTTACTGCCGACTTCACAGCCATTGACAAGATTGGCATTGCGGAC
 AGTGAACCTGTGCGTTCTGGTACATGGAGGACACATCTGCACATATTACTTTCATCAGGAGGAGCAGA
 M_E_D_T_S_A_H_I_T_F_H_Q_E_E_Q
 CTCCTGGCGTGTATGTAGTCCCACGGGAAACAATTGCAGCCCTGAACCCCAATAAAATTCTGGCATT
 T_P_G_R_V_C_S_P_T_G_N_N_C_S_P_E_P_Q_*
 TACAGTGCATTGAGCTTCCGGGGATCTTGAGTCATGAAGGTGAGTACAATAGATCCGCTGGTCGC
 AGTACACATACAAATGTGTACACATGTGGTGGCGATGCCCGGTGGCTACACGAGTCGAGGTGACTG
 M_C_T_H_V_V_A_M_P_G_V_A_Y_T_Q_S_R_*
 M_W_W_R_C_P_A_W_L_T_R_S_R_G_D_*
 ACCTTCGGCCAAATCGGAAAGGTCGACATGAATGATGCCGACTAGAAAGGAAGGGAAAGGCCGAAA
 M_N_D_A_A_L_E_R_K_G_K_A_G_K
 GTAAGCGTTCCCCACGCAGCCCCACGCAAAGTCATGGCATATATAATTGTTTAAACCAATGCTATT
 V_S_V_P_H_A_A_P_T_Q_S_H_G_I_Y_N_S_F_*
 M_A_Y_I_I_R_F_K_T_N_A_I_
 M_L_L
 GCAAAAGGATAGAGATGTACCGGTCTAAGCATTAGGTGCTGGACTGACGGCGCAAGGAATGCTAA
 A_K_G_*
 Q_K_D_R_D_V_P_V_L_*
 M_Y_R_S_S_K_H_S_G_A_G_L_T_A_A_R_N_A_K
 M_L
 AAGATTGCATGCCAGTAGCAACCTTTAGTAGAAGACATTTCGAGTAGGGGGCGGTACGCCGTTTGG
 R_L_H_A_S_S_N_L_L_V_E_D_I_F_R_V_G_G_T_P_F_W
 K_D_C_M_P_V_A_T_S_*
 GCATAGTCCTCCAAGTCTTACATAATGTTGAAAATGTGTGAGGTGCTCGTGTGACCGAG
 A_*
 M_T_L_H_K_C_S_K_M_C_E_V_L_R_D_Q
 CCAATCACTCGTCACAGCTCAAGGACGATTGACGCTTCATCCATTGAAGCAGACTGGCGACTGGAGTT
 A_N_H_F_V_T_A_Q_G_R_F_D_A_S_S_I_E_A_D_W_R_L_E_L
 GACTACACAGAAGCTAGAGCTAAATGGCATGCTGGAGAACAAAGCTTTACAAAGGATATATAG
 T_T_Q_K_L_* M_L_A_K_N_K_L_L_Q_R_I_Y_S
 CCGTGTTCATTAGTCTTGCAACAAAGGCAGAACACTGAGAAACTGTGACAGGACTCACACAGAGCAAAT
 R_V_H_*
 ATGTGGCGCGACAATTATGAAGGCCTTTCAGAAAGCTTCAGGGGATTACGAGAACCTCATAGA
 M_K_A_F_F_R_K_L_Q_G_D_Y_E_N_L_I_D
 TCCAAGCTTAATTGAAATTCTCCTCAGTCGCCAAGCTGTGGCCGCTGTTGGAGGGTAATGTTAAGTAG
 P_S_L_I_R_I_L_L_S_R_P_S_C_G_P_L_L_E_G_N_V_K_*
 GTAAAACATCCATTCAAGGGAGTCAGTCAAATCGACGGCTACGTCGATTGGCAAGGATGTTCACCAAG
 CAACATCTGGCTAGCCCTGGTACAGAAACCATGGTATAACCAGGGCATACTGAGACTGTACGTGAAGA
 ACGCCTGGTAATTGGATCAATGGCTTAGACCTAGAGCCTGTATCCCTGGCATGTTGAGTATTAA
 TTATTATATACTTACAGAATTCTCACCGGGACTGTGTACCGATGTTGAGAAGATGTGGAACAGCC
 AAGGAGACTGTGGTGGCATGGCATACTTGACGGTGACGAGGCGTGCACCGCCCCAAATCACTGCAC

TGGCTGAACACTGCAAGAGGATGCACTCAACCATCATCATTGGATGTGATGCAAATGCACATCACGTAAT
 ATGGGGCACCGCGTCGCCAACGAAACGCAGCATGCCTACATGGCGGGAAAGATCAACTGATACTGCCCTA
 M_G_H_Q_A_S_P_T_N_A_A_C_L_H_G_G_K_I_N_*
 M_P_T_W_R_E_D_Q_L_I_L_P_Y
 TATCACCTGAAAAGCCTTATTGAGGATTCACTGACTCATAAGGAAGTGGCGTTATGTGCCTCTTAGACA
 I_T_*
 M_C_L_L_R_H
 TACAGGGTGCATTCGACAATACTCCCATGAAGCTGTCAACGCATCCCTGGCAAGAAGAGGACTAGATGC
 T_G_C_I_R_Q_Y_L_P_*
 M_K_L_S_T_H_P_W_Q_E_E_D_* M
 AACAAACCAGCAGATGGATCAAGTCACTACTGGCATCTAAGCGAGCCATGGCCACTATAGGAGGGCAGTCG
 Q_Q_P_A_D_G_S_S_H_Y_W_H_L_S_E_P_W_P_L_*
 TCCACAGTACCTACCACAAGAGGTTGCTCCAAGGGGGTGTCTCGCCTCTCCTGTGGAGCTGCTGG
 TACCGCAGTTGCTGGACAGACTGACCCAGAGGTATACTTGCAAGGCTATGCTGACGATATTGTCAT
 TATAGCCAGAGGTAATATGAGGAAACACTCTGCCATATCATTCAACTGGCATCAATATGACCAGCGAA
 M_R_K_H_S_A_I_S_F_N_W_A_S_I_*
 TGGTTCAAGGAAGTAGGCCTGAGCCTAAATCCTAGCAGAGAATGAAGGCAATAGCCTGTCAAAATGTGG
 M_V_Q_G_S_R_P_E_P_K_S_*
 CATAGAGGCCAGCAATGAAGTTAAGTATCTGGATAGCCCTTACTCCAAACTCAGCTCAAAACTCAT
 M
 GTCGATAACAAAATTGATAAGTGCACCAAGAGCACTTTCACGTGTAGAACATTGCTGGTAAGTCGTGGG
 S_I_T_K_L_I_S_A_P_E_H_F_S_R_V_E_T_L_L_V_S_R_G
 GAACCTCACCAACGCATAATAAGATGGCTGTACCTCATGGTAGTCAGACCCATAACTAACCTATGGGGCAA
 E_P_H_H_A_* M_A_V_P_H_G_S_Q_T_H_T_N_L_W_G_K
 GCCTAGGGTGATAGAGCACGCCCTAGCACCCTAAGGCAGAACCTCATAAGCTTCAGAGTGCCTACCTGT
 A_*
 CCCACTGTAGCCCTAGAAGTACTAGTGGAGGTGACGCCGCTTCATATCGTCACTGAAATGAAGCGGAAAG
 CCACCCATAATAAGAATTGGAGGGAGCAGGAAATGACTGCAACCTCACAAGTAAGGATGCTGAAAGCCTAAA
 M_T_A_T_S_Q_V_R_M_L_K_A_*
 AAGGGATATCCCTAGCCAAAGCAACCAAGGGATGCCAGCTGAGCATAGGTTGCTCAGAACCTCACCAC
 M_P_A_E_H_R_F_A_Q_N_F_T_T
 TCATCTCAGTAATAAGAACAGTTGGGAGCTAAGATTCTCCGTGAATATAACCATGAAAGTTCAA
 H_L_S_N_K_N_S_W_A_V_*
 GACCGTAATGACACACAGGGAAAAGACCGTGCGCATTGACTGGCCTTACTGCCGACTTCACAGCC
 ATTTGACAAGATTGGCATTGGACAGTGAACCTGTCGCTCTGGTACATGGAGGACACATCTGCACA
 M_E_D_T_S_A_H
 TATTACTTTCATCAGGAGGAGCAGACTCCTGGCGTGTATGTAGTCCCACGGGAAACAATTGCAGCCCT
 I_T_F_H_Q_E_E_Q_T_P_G_R_V_C_S_P_T_G_N_N_C_S_P
 GAACCCCAATAAAATTCTGGCATTATACAGTGCATTGAGCTCCGGGGATCTTGAGTCATGAAGGTG
 E_P_Q_*
 TAGTACAATAGATCCGGCTGGTCGAGTACACATACAAATGTGTACACATGTGGTGGCGATGCCGGCG
 M_C_T_H_V_V_A_M_P_G
 M_W_W_R_C_P_A
 TGGCTTACACGCAGTCGAGGTGACTGACCTCGGCCCCAAATCGGAAAGGTCGACATGAATGATGCCGCAC
 V_A_Y_T_Q_S_R_*
 W_L_T_R_S_R_G_D_* M_N_D_A_A
 TAGAAAGGAAGGGAAAGGCGGGCAAAGTAAGCGTCCCCACGCAGCCCCACGCAGGAAAGTCATGGCATATA
 L_E_R_K_G_K_A_G_K_V_S_V_P_H_A_A_P_T_Q_S_H_G_I_Y
 M_A_Y
 TAATTGTTTAAACCAATGCTATTGCAAAGGATAGAGATGTACCGGTCTCTAACATTAGGTGCT
 N_S_F_*
 I_I_R_F_K_T_N_A_I_A_K_G_*
 M_L_L_Q_K_D_R_D_V_P_V_L_*
 M_Y_R_S_S_K_H_S_G_A
 GGACTGACGGCGGCAAGGAATGCTAAAGATTGCATGCCAGTAGCAACCTTCTAGTAGAAGACATTTC
 G_L_T_A_A_R_N_A_K_R_L_H_A_S_S_N_L_L_V_E_D_I_F
 M_L_K_D_C_M_P_V_A_T_S_*
 GAGTAGGGGGCGGTACGCCGTTGGCATAGTCCTCCAAGTTCTATGACTTACATAATGTCGA
 R_V_G_G_G_T_P_F_W_A_* M_T_L_H_K_C_S_K
 AATGTGTGAGGTGCTTCGTGACCAGGCCAATCACTCGTCACAGCTCAAGGACGATTGACGCTCATCC
 M_C_E_V_L_R_D_Q_A_N_H_F_V_T_A_Q_G_R_F_D_A_S_S
 ATTGAAGCAGACTGGCGACTGGAGTTGACTACACAGAAGCTAGAGCTCAAATGGCATGCTTGCAG

```

I__E__A__D__W__R__L__E__L__T__T__Q__K__L__*
M__L__A__K__
ACAAGCTTTACAAAGGATATAGCCGTGTTCAATTAGTCTTGCAACAAAGGCAGAACACTGAGAAACT
N__K__L__L__Q__R__I__Y__S__R__V__H__*
GTGACAGGACTCACAAACAGAGCAAATATGTGGGCGCGACAATTATGAAGGCCTTCAGAAAGCTT
M__K__A__F__F__R__K__L__
CAGGGGATTACGAGAACCTCATAGATCCAAGCTTACTCGAATTCTCCTCAGTCGCCAATATGCCCA
_Q__G__D__Y__E__N__L__I__D__P__S__L__L__R__I__L__L__S__R__P__I__S__P__
AGCTGTGGCCCGCTGTTGGAGGGTAATGTTAAGTAGGTAAACATCCATTCAAGGGAGTCACTGCAAATC
K__L__W__P__A__V__G__G__*
GACGGCTCACTTAT

```

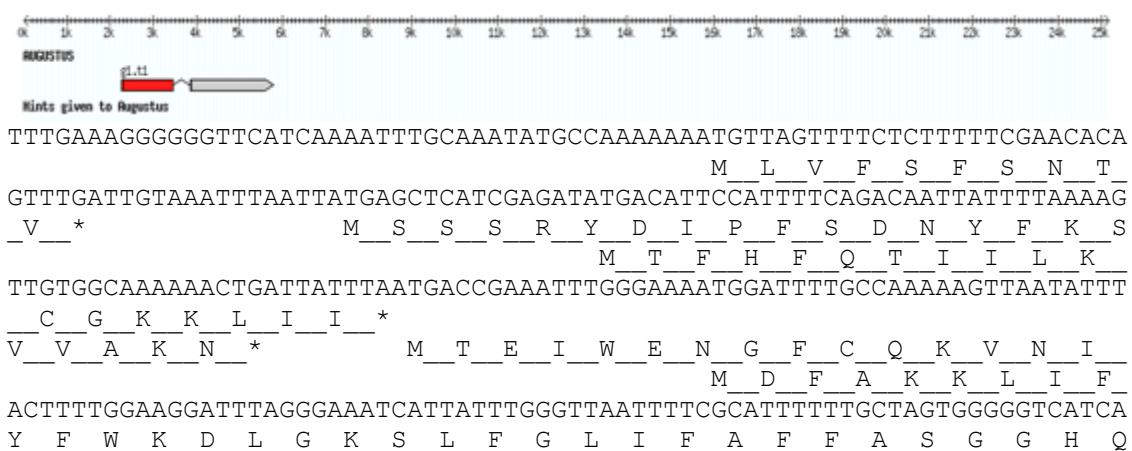
Para el gen 2L_105, el programa Augustus Gene Prediction predijo una estructura compuesta por 6 exones de 839 pares de bases el primero, 122 pares de bases el segundo, 215 pares de bases el tercero, 623 pares de bases el cuarto, 122 pares de bases el quinto, y 375 pares de bases el sexto, y 5 intrones de 135 pares de bases el primero, 55 pares de bases el segundo, 1970 pares de bases el tercero, 135 pares de bases el cuarto y 55 pares de bases el sexto.

Se encontró acuerdo con espectros de masas para el péptido FAQNFTHLSNKNSWAV con una probabilidad de $p=0.062$ y un valor E=0.000251395072294928, y para el péptido DQANHFVTAQGRFDASSIEADWR, con una probabilidad de $p=0.027$ y un valor E=0.000168306701192261.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 43 sORFs. Se pueden observar repeticiones. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 2 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_108



T F G R I *
 AAATTTGAAAGATATGCCAAAAAAATGTAATTTCGTTGTAACACAGTTCATTGGAAATTAAATTA
 N L K D M P K K M *
 TGAGCTCATCGAGATATGACATTCCATTTCAGACAATTATTTAAAAGTTGTGGCAAAAAACTGATTAT
 M S S S R Y D I P F S D N Y F K S C G K K L I I
 M T F H F Q T I I L K V V A K N *
 TTAATGACCGAAATTGGAAAAACGGATTTCGCACAAAGTTAATATTCCTTTGAAGGAGTTAGGGAA
 * M T E I W K N G F C Q *
 AATCATTATTTGTGTACATTTCGCACATTGGAAAGGGGGTTCATCAAAATTGCAAATATGCCAAA
 M P K
 AAATGTTATTTTCTCTTTGCAACACAGTTGATTGTAATTAAATTATGAGCTCATCGAGATATGA
 K C Y F F S F S N T V *
 M L F F L F F E H S L I V N L I M S S S R Y D
 M
 CATTCATTTCAGACAATTATTTAAAAGTTGTGGCAAAAAACTGATTATTAATGACCGAAATTGGAA
 I P F S D N Y F K S C G K K L I I *
 T F H F Q T I I L K V V A K N * M T E I W
 AAAACGGATTTCGCACAAAGTTAATATTTACTTTGAAAGGAGTTAGGGAAATCATTATATGGGTTAAT
 K N G F C Q K V N I Y F W K D L G K S L Y G L I
 TTTCGCACATTGGCTAGTGGGGGGTCATCAAAATTGAAAGATATGCCAAAAAAATGTAATTTCATTG
 F A F F A S G G S S K F E R Y A K K M *
 M P K K C N F H C
 TTGAACACAGTTCATGGAAATTAAATTACGAGCTCAGCGAGGTATGACATTTCATATTGACACAATTA
 * M T F H I Q T I
 ATTTAAAGTTGTGGCAAAAAACTGATTATTAATGACCGAAATTAGGGAAATCAGATTGCAAAAG
 N F K V V A K K L I I * M T E I R E S D F A K K
 TTGTTATTTACTTTGAAAGGAGTTAGGGAAATCAATTGGCTTAATTTCGCACATTGGAAAGGGG
 L L F T F *
 GGTCATTAATGCAAATATGCCAAAAATGTAATTTCATTGTTGAAACACAGTTCATGGAAAT
 M P K K C N F H C *
 TTAATTACGAGCTCAGCGAGGTATGACATTTCATATTGACACAATTATTTAAAAGTTGTGGCAAAAAA
 M T F H I Q T I I L K V V A K K
 CTGATTATTAATGACCGAAATTAGGGAAATCGGATTTCGCACAAAGTTTATTTACTTTGAAAGGAT
 L I I * M T E I R E S D F A K K F L F T F *
 TTAGGGAAATCAATTGGCTTAATTTCGCACATTGGAAAGGGGGTTCATCAAAATTGCAAATAT
 M
 GCCAAAAAAATGTTATTTCTTTGCACACAGTTGATTGAAATTAAATTATGAGCTCATCGAG
 P K K C Y F S L F C T Q F D C K F N Y E L I E
 M L F F S F L H T V * M S S S R
 ATATGACATTCCATTTCAGACAATTATTTAAAAGTTGTGGCAAAAAACTGATTATTAATGACCGAAA
 I *
 Y D I P F S D N Y F K S C G K K L I I *
 M T F H F Q T I I L K V V A K N * M T E
 TTTGGAAAAATGGATTTCGCACAAAGTTAATATTTACTTTGAAAGGAGTTAGGGAAATCATTATTG
 I W K N G F C Q *
 M D F A K K L I F T F G R I *
 GTTAATTTCGCATTGGCTAGTGGGGTCATCAAAATTGAAAGATATGCCAAAAAAATGTAATT
 M P K K C N F
 CATTGTTGAAACACAGTTCATGGAAATTAAATTACGAGCTCAGCGAGGTATGACATTCCATTTCAGAC
 H C * M T F H F Q T
 AATTATTTAAAGTTGTGGCAAAAAACTGATTATATAATGACCGAAATTAGGGATACTGGATTTCGC
 I I F K V V A K K L I I * M T E I R D T D F A
 AAAAGTTGTTATTTACTTTGAAAGGAGTTAGGGAAATCAATTGGCTTAATTTCGCACATTGGAA
 K K L L F T F *
 AGGGGGGTTCATCAAAATTGCAAATATGCTGTTGGAATATACTATTCAACCTACAAAATAACGTTAAA
 CAACACTACCTTATATTGATATGAATGCCACACCTTTATGCCATAAAACATATTGTGAGAGAATAC
 M N G H T F Y A I K H I V R E Y
 CACTCTTTATTCCCTCTTCTGTACGTTTGCTGTGAGTAGGTGCTGGTGTGGTGTGCA
 H S F Y S F S S L Y V F A V S R S W C W C C
 GTTGAATAACTAAATATAATCATAAAACTCAAACATAACTGACTATTATTATTATTAAGAA
 S *

AGGAAATATAAATTATAAATTACAACAGGTTATGGGCCAGTCCATGCCTAATAAACAAATTAAATTGTGA
 M_P_N_K_Q_L_N_C_E
 ATTAAAGATTGTGAAAATAATTGTGAAATAGCATTTCACATTCTGTGAAATAGCTTTTTCA
 L_K_I_V_K_I_N_C_E_I_A_F_F_H_I_L_V_K_*
 CATTCTGTGAAATTATTCCTCTCAGAATTGAGTGAAAATGGACAAGGCTAACGTAATATTAAGC
 CGTTTGATGGCGAGAAGTACCGCAGTTGAAATTAGGCTCTTAGCCGAGCAAGATGTGCT
 M_A_R_S_T_R_F_G_N_L_E_L_G_L_F_*
 TAAAGTAGTTGATTGTTAATGCCTAACGAGGTAGATGACTCCTGGAAAAAGGCAGAGCGTTGTGCAAAA
 M_T_P_G_K_R_Q_S_V_V_Q_K
 AGTACAATAATAGAGTACCTAACGACTCGTTAAATTGCAACAAGCGACATTACGGCGCGTCAGA
 V_Q_*
 TTCTTGAGAATTGGACGCCGTTATGAACGAAAAGTTGGCGTCGCAACTGGCGCTGCGAAAACGTT
 M_N_E_K_V_W_R_R_N_W_R_C_E_N_V
 GCTTCTCTGAAGCTATCGAGTGAGATGTCACTATTAAGCCATTTCATATTTGACGAACATTAAAGT
 C_F_L_*
 GAATTGTTGGCAGCTGGTGCAGGAAATTAGAAGAGATGGATAAAATTCTCATCTACTGATCACATTGCCTT
 CGTGTACGATGGAATTATTACAGCGATAGAGACATTATCTGAAGAAAATTGACATTGGCGTTGTGAA
 AAATAGATTGCTGGATCAAGAAATTAAAATTAAAATGACCACAACGATACAAGCAAGAAAGTTATGAAC
 M_T_T_T_I_Q_A_R_K_L_*
 GCGATCGTCACAACAATAATAACACTTATAAAAATAATTGTTAAAATCGGGTAACTAAACCAAAGA
 AAATATTCAAGGGAAATTCAAAGTATAAGTCAAGTGTCAACCCTGTGGCAGAGAAGGCCACATTAAAAA
 AGATTGTTCCATTATAAAAGAATATTAAATAATAAAATAAGAAAATGAAAAGTTCAAACGCA
 M_K_N_K_F_K_L_Q
 ACATCACACGGCATTGCGTTATGGTAAAAGAAGTGAATAACTTCAGTGTGACAACTGCGGTTG
 H_H_T_A_L_R_L_W_*
 TCCTTGATTCTGGTGCTAGTGACCATCTTATAATGATGAGTCGCTGTACCGACAGTGTGGAGGTTGT
 GCCTCCACTTAAGATTGCACTGGCCAAGCAAGGCGAATTATTGCAACTAAGCGTGGTATTGTCCGA
 CTACGGAATGACCATGAGATTACACTGGAGGATGACTCTTGTAGGAAGCTGCTGGTAATTGATGT
 CCGTAAAGCGTCTCCAAGAGGCAGGAATGTCGATCGAATTGACAAAAGCGGTGTAACCATTGAAAAAA
 AAATGGGTTAATGGTTGTCAAAATTCAAGGTATGTTAACATGTACCTGTGATCAATTTCAGCATAT
 TCTATAATGCTAACGATAAAAATAATTTCGTTATGGCATGAGAGGTTGGCCATATAAGCAATGGCA
 M_L_S_I_K_I_I_F_V_Y_G_M_R_G_L_A_I_*
 AATTATTAGAAATAAAACGAAAGAATATGTTAGTGATCAAAGTCTAAACAACTTAGAGTTATCATG
 TGAAATTGTAACCTGTTAAATGGTAAACAGGCAAGACTCCTTTAAACAATTGAAAAGATAAGACC
 M_V_N_R_Q_D_F_L_L_N_N_*
 CATATTAAAAGACCACTTTGTTAGTGACTCAGATGCTGTGGGCCTATTAAATCCAGTTACTTAGATG
 M_S_V_G_L_L_I_Q_L_L_*
 ATAAAAAATTATTTGATCTTGTTGATCAGTTACATTGTAACATTGTTGTAACTTATTAAATTAAATATAA
 ATCTGATGTGTTAGCATGTTCAAGATTGTTGAGCCAAGAGTGAAGCTCATTAAATTAAAGGTTGTG
 M_C_L_A_C_F_K_I_L_*
 TACTTATACATTGACAATGGTAGAGAATACTTGTCAAATGAGATGAGACAATTGTTGTTAAGAAAGGAA
 M_V_E_N_T_C_Q_M_R_*
 TTTCTTACTTAACAATGCCACATACACCTCAGTTAAATGGTTCTGAGAGAATGATAAGAACCAT
 TACGGAAAAAGCTCGAACCATGGTTAGGGTGCAAAGCTAGATAAAAGCTTGGCGAAGCAGTATTAA
 ACTGCTACTTATTAAACAGAACATTCTAGCAGAGCACTGTTGATAGTCAAAGACCCATATGAGA
 M_R
 TGTGGCACAATAAGAACCCATACTTAAACATTGAGAGTGTGTTGGTGCACACTGTTATGTGCATATTAA
 C_G_T_I_R_S_H_T_*
 AACAAACAAGGAAAGTTGATGATAAAATCATTAAAGTATTGTTGGCTATGAACCCAAATGGTTTT
 K_T_N_K_E_S_L_M_I_N_H_L_K_V_F_L_W_A_M_N_P_M_V_L
 AAGTTGGGATGCTGTAATGAAAATTATTGTCGCAAGAGATGTTGTCGATGAAACCAATATGG
 S_C_G_M_L_* M_K_N_L_L_S_Q_E_M_L_L_S_M_K_P_I_W
 TTAATTCTAGAGCTGTTAAATTGAAACAGTGTGTTGAAAGATAGTAAGGAAAGTGAAAATTTAA
 L_I_L_E_L_L_N_L_K_Q_C_S_*
 TCCGAATGACAGTAGGAAAATAATACAAACAGAGTCCGAAATGAGAGTAAGGAATGCGACAACATA
 M_R_V_R_N_A_T_T_Y_N
 M_R_Q_H_T
 TTCCTGAAAGATAGTAAGGAAAGTGAAAATAATTGAAACAGTGTGTTGAAAGATAGTAAGGAAAGTGAAAATTT
 S_*
 I_P_E_R_*
 AATTCCGAATGAGAGTAAGGAATGCGACAACATAACATTGAAAGATAGTAAGGAAAGTGAAAATTTAA

M_R_V_R_N_A_T_T_Y_N_S_*
 M_R_Q_H_T_I_P_E_R_*
 TTTTCTGAATGAGAGTAAGAAAAGAAAGCAGAGATGATCACCTGAATGAAAGTAAGGGATCAGGCAACCCG
 M_R_V_R_K_E_S_E_M_I_T_* M_K_V_R_D_Q_A_T_R
 AATGAGAGTAGGGAAAGTGAAACAGCAGAGCACTAAAAGAAATTGGAATTGATAATCCAACAAAAATG
 M_R_V_G_K_V_K_Q_O_S_T_*
 ATGGCATAGAAATTATTAATAGAAGAAGTGGAGAGATTAAAGACTAACGCCTAGATATCCTATAATGAAGA
 GGATAATAGTCTAAATAAGTTGTTCTAAATGTCACACTATTTAACGATGTCCCAAATTCTATTTGAT
 M_L_T_L_Y_L_T_M_S_Q_I_H_L_M
 GAAATTCAATATAGGGATGATAATCTTCTGGGAAGAACCCATCAATACAGAGTTAAATGCTCATAAAAA
 K_F_N_I_G_M_I_N_L_L_G_K_K_P_S_I_Q_S_* M_L_I_K
 TTAATAACTTGGACAATTACAAAAGGCCTGAAAACAAAATATTGTAGATAGCAGATGGGTATTTTC
 L_I_I_L_G_Q_L_Q_K_G_L_K_T_K_I_L_*
 TGTTAAATATAATGAACCTGGAAATCCAATTAGATACAAAGCTAGATTGGTGCACGAGGATTCACTCAA
 M_N_L_E_I_Q_L_D_T_K_L_D_W_L_H_E_D_S_L_K
 AAATACCAAATAGACTATGAAGAGACATTGCTCTATAGCTAGAATTCAAGTTCCGATTATATTGT
 N_T_K_*
 CATTAGCAATACAGTATAACTGAAAGTCCATCAAATGGATGGATGAAAAACAGCTTCTAAATGGCA
 CGTTAAAAGAGGAAATTATGAGACTCCTCAAGGTATATCGTGTAAATAGTGACAATGTGTGAAATT
 GAATAAGGCAATTACGGACTCAAGCAAGCGGCTAGATGCTGGTTGAAGTATTTGAGCTAGCATTGAAA
 GAGTGTGAGTTGTAAACTCTCAGTTGATCGCTGTATATATTTAGACAAAGTAACATCAATGAAA
 M_K_
 ACATATATGTATTATTATGTAGATGATGTGGTTAGCTACAGGAGATATGACAAGAATGAATAACTT
 T_Y_M_Y_Y_M_*
 CAAAAGGTATTAAATGGAAAAGTTAGGATGACTGACCTAAATGAAATAAAACATTTATTGAAATTAGG
 ATAGAGATGCATGAAGATAAAATCTATTAAAGCCAATCTGCATATGTTAAAAAAATTAAAGTAAATTAA
 ACATGGAAAATTGTAATGCAGTTAGTACTCCTTACCTAGTAAATAATTATGAATTACTTAATTCA
 M_Q_L_V_L_L_Y_L_V_K_* M_N_Y_L_I_Q_
 TGAAGACTGCAATACCCCATGCCGTAGCCTCATAGGATGTTAATGTACATAATGCTTGTACACGCCA
 M_K_T_A_I_P_H_A_V_A_S_* M_F_N_V_H_N_A_L_Y_T_P_
 GATTTAACTACTGCAGTAAATATCTTGAGCAGATATGTTAGCAAGAAAATACTCGAATTATGGCAGAACT
 R_F_N_Y_C_S_K_Y_L_E_Q_I_*
 TAAAAAGAGTTCTAGATATTGAAGGGCACTATCGATATGAAATTGATTTAAAAAGAACTTGGCATT
 TGAAAATAAAATTATTGGTTATGTGGATTCTGATTGGCTGGTAGTGAAATTGATAGAAAAGTACAACA
 M_W_I_L_I_G_L_V_V_K_L_I_E_K_V_Q_Q
 GGGTATTATTCAAAATGTTGATTTAATCTCATTGTTGGAATACAAAGAGACAGAACTCAGTAGCAG
 G_I_Y_S_K_C_L_I_L_I_S_F_V_G_I_Q_R_D_R_T_Q_*
 CCTCATCAACTGAAGCTGAGTATATGCCCTATTGAAGCCGTGAGAGAAGCTCTATGGCTTAAATT
 ATTAACTAGTATTAAACATTAAACTAGAAAACCCATTAAAATTACGAAGACAATCAAGGCTGTATTAGC
 ATAGCAAACAACCCCTCATGTCAAAACGAGCTAACATATTGATATTAAATATCATTGCCCCAGAGAGC
 AAGTTCAAGATAATGTGATTGTCTTGAGTATATTCTACAGAGAATCAACTGGCTGACATATTACAAA
 ACCGTTGCCTGCTGCGAGATTGTGGAGTTACGAGACAAATTGGTTGCTGCAAGACGACCAATCGAAT
 M
 GCTGAATGAAATTATATATTTCAAATTAAATTCTGTAAACATATTGTTACAATGATCTG
 L_N_E_I_F_I_Y_I_F_Q_I_*
 M_K_F_L_Y_I_F_F_K_F_K_F_L_*
 ATCGGGTTTCTGGTTTCCCGTATCCTCGCAGCAAATGCTGGATCAGTTAACACTCCCAGAATGC
 M_L_D_Q_L_T_L_P_R_M_
 ACACCACCCACATTGATAGTTACTAATGAATATTGTTATGTTAAATTAGACGTTATTGAT
 H_T_T_H_I_* M_N_I_I_V_M_F_L_I_I_D_V_I_F_E
 GGGGGCGTGTGGAATATACTATTCAACCTACAAAATAACGTTAAACAAACACTACTTATATTGATAT
 G_A_C_W_N_I_L_F_N_L_Q_K_* M
 GAATGGCCACACCTTTATGCCATAAAACATATTGTGAGAGAATACCACTTTTATTCTCTTTCT
 N_G_H_T_F_Y_A_I_K_H_I_V_R_E_Y_H_S_F_Y_S_F_F_S
 TCCTTGTACGTTTGCTGTGAGTAGGTCGTGGTGTGCTGGTGTGCAAGTTGAAATAACTTAAATATAAAT
 S_L_Y_V_F_A_V_S_R_S_W_C_W_C_C_S_*
 CATAAAACTCAAACATAAAACTGACTATTATTTATTAAAGAAAGGAAATATAAATTATAAATTACA
 ACATATGCCGAAAAATGTAATTTCATTGTTGAACACAGTTTATTGAAATTACGAGCTCAGC
 M_P_K_K_C_N_F_H_C_*
 GAGGTATGACATTCCATATTCAACATAATTAAAGTTGAGGCAAAAAACTGATTATTAAATGACC
 M_T_F_H_I_Q_T_I_N_F_K_V_V_A_K_K_L_I_I_*

CAAATTGGAAAAACGGATTTGCCAAAAGTTAATATTCCTTGGAGGATTAGGAAAATCATTAT
 TTGGGTTAATTCGCATTTGCTAGTGGGGTCATCAAATTGAAAGATATGCCAAAATGTGAT
 M_P_K_N_V_I
 TTTCATTGTTAACACAGTTCATGGAAATTAAATTACGAGCTCAGCGAGGTATGACATTCCATATTCC
 F_I_V_E_H_S_F_I_G_N_L_I_T_S_S_A_R_Y_D_I_P_Y_S
 M_T_F_H_I_P
 AACAAATTATTTTAAAGTTGTGGCAAAAAACTGATTATTAATGACCGAAATTAGGGAATCAGATTTG
 N_N_Y_F_*
 T_I_I_F_K_V_V_A_K_K_L_I_I_* M_T_E_I_R_E_S_D_F
 CAAAAAAAGTTGTATTACTTTGAAGGATTAGGGAAATCAATTTCGTTAATTTGCATTTT
 A_K_K_L_L_F_T_F_*
 GAAAGGGGGTTCATAAAATTGCAAATATGCCAAAAATGTAATTTCATTGTTAACACAGTTCA
 M_P_K_K_C_N_F_H_C_*
 TTGGAAATTAAATTACGAGCTCAGCGAGGTATGACATTTCATATTACAGACAATTAAATTAAAGTTGTGG
 M_T_F_H_I_Q_T_I_N_F_K_V_V
 CAAAAAAACTGATTATTAATGACCGAAATTAGGGATACGGATTGCAAAACTTGTATTACTTT
 A_K_K_L_I_I_* M_T_E_I_R_D_T_D_F_A_K_N_L_L_F_T_F
 TGAAGGATTAGGAAATCAATTTCGTTAATTTGCATTTTGAAAGGGGGTTCATCAAATT
 *
 GAAAGATATGCCAAAAATGTGATTTCATTGTTAACACAGTTCATGGAAATTAAATTACGAGCTC
 M_P_K_K_C_D_F_H_C_*
 AGCGAGGTATGACATTCCATATTCCAACAATTATTTAAAGTTGTGGCAAAAAACTGATTATTAATG
 M_T_F_H_I_P_T_I_I_F_K_V_V_A_K_K_L_I_I_* M
 ACCGAAATTAGGGATACGGATTGCAACAAGTTGTATTACTTTGAAGGATTAGGGAAATCAAT
 T_E_I_R_D_T_D_F_A_N_K_L_L_F_T_F_*
 TTTGGGTTAATTCGATTTTGAAAGGGGGTTCATCAAATTGCAAATATGCCAAAAATTAA
 M_P_K_K_F
 ATTTCATTGTTAACACAGTTCATGGAAATTAAATTACGAGCTCAGCGAGGTATGACATTCCATATT
 N_F_I_V_E_H_S_F_I_G_N_L_I_T_S_S_A_R_Y_D_I_P_Y_S
 M_T_F_H_I
 AAACAATTATTTAAAGTTGTGGCAAAAAACTGATTATT
 N_N_Y_F_*
 Q_T_I_I_F_K_V_V_A_K_K_L_I_I_*

Para el gen 2L_108, el programa Augustus Gene Prediction predijo una estructura compuesta por 2 exones de 1190 pares de bases el primero y el segundo de 1933 pares de bases, y 1 intrón de 407 pares de bases.

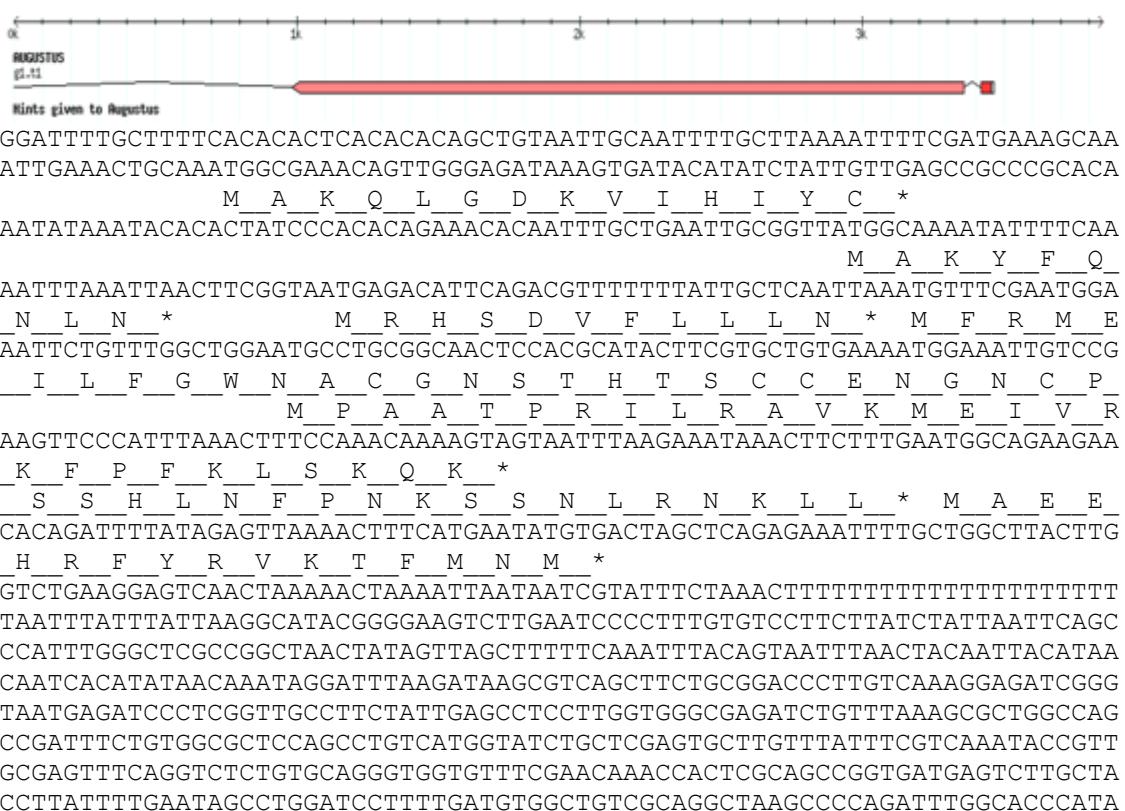
Se encontró acuerdo con espectros de masas para el péptido LFFSFLHTV con una probabilidad de $p=0.02$ y un valor $E=2.18235564894947e-05$; para el péptido MTFHFQTIIFK con una probabilidad de $p=0.048$ y un valor $E=0.000541665926594377$; para el péptido TFHIQTIIFKVVAK con una probabilidad de $p=0.077$ y un valor $E=1.74494226863423e-05$; para el péptido LFFSFLNTV con una probabilidad de $p=0.012$ y un valor $E=1.95068835446376e-05$; para el péptido IVKINCEIAFFHILVK con una probabilidad de $p=0.033$ y un valor $E=0.000103692423625058$; para el péptido KFNFIVEHSFIGNLITSSAR con una probabilidad de $p=0.007$ y un valor $E=0.000672127891608788$; para el péptido GVHQNLQI con una probabilidad de $p=0.083$ y un valor $E=0.000381138123940895$; para el péptido TLHFQTIIFKVVAK con una probabilidad de $p=0.077$ y un valor $E=0.000121002071622241$; para el péptido MTFHIQTINFK con una probabilidad de $p=0.088$ y un valor $E=4.77278654852789e-05$; para el péptido ESLMINHLKVFLWAMNPMLSCGML con una probabilidad de $p=0.065$ y un valor $E=0.000261882533564455$; para el péptido VFLWAMNPMLSCGML con una probabilidad de $p=0.091$ y un valor $E=0.000896475383408014$; para el péptido FNIGMINLLGK con una probabilidad de $p=0.044$ y un valor $E=0.00021280221052333$; para el péptido LIKLIILGQLQK con una probabilidad de

$p=0.051$ y un valor $E=9.11628258769806e-05$; para el péptido VQQGIYSKCLILISFVGQIQR con una probabilidad de $p=0.012$ y un valor $E=3.55732257113095e-05$; para el péptido MWILIGLVVK con una probabilidad de $p=0.01$ y un valor $E=1.93761506518799e-05$; para el péptido NIIVMFLIIDVIFEGACWNILFNLLQK con una probabilidad de $p=0.065$ y un valor $E=0.00023267886555133$; para el péptido DLGKSIFALIAFFER con una probabilidad de $p=0.099$ y un valor $E=0.000145335264384092$; para el péptido VVIYFLKDLGK con una probabilidad de $p=0.064$ y un valor $E=0.000143336854414044$; para el péptido DLGKSLFGLIAAFFVSGGHQNLK con una probabilidad de $p=0.047$ y un valor $E=0.000584690172889705$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 73 sORFs. Se pueden observar repeticiones. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 19 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_120



M_W_L_S_Q_A_K_P_Q_I_W_H_P_Y
 CTTCCAGTTGGTGTAGGATCTGTTGAAATTGTCAGCTTGGATAGCACAATTACTGCGCGAA
 _F_Q_F_G_A_R_I_C_L_*
 GAAAGTAGCCAGTAGTGCTCGCACCTAGCACGTAGGCACGTTCTGATGTCGGTCACATGCTGGAAA
 M_S_V_T_C_L_E
 M_L_G_K
 ATGTGAGTCTGCGATCCAGAAGCACTCCAAGGTACTTGCTGCGTTGGCTGTGGTACGGGACTTCCTC
 N_V_S_L_R_S_R_S_T_P_R_Y_F_A_A_F_G_C_G_T_G_T_S_S
 _C_E_S_A_I_Q_K_H_S_K_V_L_C_C_V_R_L_W_Y_G_D_F_L
 GATGTAGACGGCGGTGGCGTTCTCGCTTAAGTGAAGCAGACGTTGGATTACTGCTATTGATG
 M_*
 D_V_D_G_R_W_R_S_P_L_*
 M_
 CCAATATCCATCGTCTGCCATTCCGAGAACCGGTATGCAAAGTCCTGGATACCACGGCTGCGTCGT
 P_I_F_H_R_L_A_H_S_E_N_R_Y_A_K_S_W_I_P_S_A_A_S
 M_Q_S_P_G_Y_H_R_L_R_R
 GCTCGCATCGGACCTGTAGGTGACGCACACGTACGGCAAATGTGGCCAACATAGATTCCGTAAAG
 C_S_H_R_D_L_*
 A_R_I_G_T_C_R_*
 GCTTACATCTGGCTGCGCATGTCGTGGCTATACAGGCAGTAGAGCAGGGGCCGAGGACACTACCTTGT
 GGAACACCAGCTGCCACGTTGTGCTCGGTGGAAATTGCTGAATGAAAGCGCACAGCGAACCTCCCT
 CCAGGTACGATTCAGCAACCCAAAATATGGAGCAGGCAGCGTCTGCTGATTTCAGTTGGAGTCCAAT
 M
 GTGCCACACTCGATCAAACGCTCTCGAATGTCCAAGAAGAGGCTGTTACAATATTCCCTACTGCGTAG
 C_H_T_R_S_N_A_S_R_M_S_K_K_R_L_L_Q_Y_S_L_L_S_*
 GCAGTCAGAATTGCTCGACGACTCGATGGAGCTGCTCGACAGTACAGTGGCCAGCACGGAAACCGAAC
 GGTGCTAGGGTAATCCCCTGGCTTCCATAATCCTTACAATCCGGACAGCAATCAGTCTCAAACAC
 CTTCGAAATTGAAGGGAGGAGACTGATCGGCCGGTAGGAGGGCTCCCTTCCGGTTGCCAGGTTG
 TGGATCATGGAGATTATCCGAGCTTCACTGATAAGGAAAGTATTGCAACCTCACAATAGCGTTGAAAA
 CCAACGTTATGTAGAGGATCGCTGTGGCAGGGCTTCAATGTGGCGTTGCAGATGACGTATGTCC
 M_T_S_C_P
 AGGTGCTTGTGTTACTCTGGCGACAATGACTTCGGTACCTCGCAGGGTTCAAACGGCGTGTGGC
 G_A_L_L_L_W_R_T_M_T_S_A_T_S_Q_G_S_N_G_V_I_G
 ATATCCATTGAAAGCGCTTGGTTCACTGGCTTCAACCTGTTGCAGGCTGGCAAGCTTGA
 I_S_I_*
 ATGGTTGAAATCGCTGGCGAGGTGCGCAGCGAATACCTCCGCTTGTCCAAGTCGGTCCGACACCATGT
 M_V_E_I_A_R_R_G_A_Q_R_I_P_P_L_V_P_S_R_S_D_T_M
 CCCGTTGCTATCGACTAGAGGCGCCTCCTCGTGAACGCCTTGATTGCGCGTGGCCTCCACAGC
 S_R_C_Y_R_L_E_A_P_S_S_C_N_A_F_*
 GAATGCGTCGCTCGTTCACTCCGGTATTGGCAAGCCTTGTGCAACCATGGCGTTGTGCAGCA
 M_R_L_C_A_A
 CCAACGCGCATGGAGCCTACTCAGAGCTGGTCCATTCCGTTGTCCGACGGGTGCCGAGACCTCAT
 P_T_R_I_G_A_Y_S_E_L_G_S_I_P_F_C_P_T_G_A_E_T_S
 CCACCTAGTGCCTAGCGCTTCTCGTATAAGCAGCAGGATCTCCCTGGGTATTGGGATTCGATCT
 S_T_*
 GCCGCGGGCTGCCGAGATATGCTGCGAGTTGCAATCTAGCTGCTGACTTGATATTGTTGGTAGCAGTT
 CGATAGCATCATCAACGTCCTGTCCAGAGTTATGGCAGTGTGAGGGCAGTGTGGACTCCAGTTGC
 TTGGAATACCTCCAGGTTAGTACGCTAGTGATAAGCGCTCCATCTAGGTAGGATATTGCCCGCA
 TCCAGCGTAATTACCAAGAGGCGAGGTGGTGGAGCTAAGCTCAACAACCGCACTTATGTTAGCGTGG
 CCAGCACACCCCTTGTCACTGCAAATCGATGTACCGCTGTGAGCCTCTACAGCCGTACGGGTATCT
 TGGCCTCCTGTGCTAGCGAGTCCACCTCGAATTAGGACGAGATTGCTAATGCAATGCCCTTTGG
 M_Q_C_L_F_G
 TTGCTCCTCCGCACCCAGAGCCAGTGGACGCGTCCAATGCCCTGCAACAAGAACCTCGTCTGGAA
 C_S_F_P_H_P_R_A_S_G_T_R_S_N_R_L_Q_Q_*
 CTCTTCCAAAATGTCCTAAACTCGTCCGTAGTCCATGCAAATCTGGTGGCAGTAGACCGCTCCAAAG
 M_Q_I_S_V_G_S_R_P_L_Q_S
 CTTATAGGACCAAGTGCCGTTCAATAACGCCGGCGCAAGTTGCACCTGGCAGTGGCTATTGGTGT
 L_*
 GCGGAAAGTGGCAAGGCTATTGATTAAGATAGCTGCTCCGCTTGGCAGTGGCACCACCTCGGATC
 ATTGGCAGTGTAGGCTACAAATCGAATAGCTTAGGCGTCTCTGCCCCCTGAGTGTCTCGCTGAGC
 AGTAATACATCGATTCGTGACGTGCGACGAAGCAGTCACTCAGGCACTCTACTCTACGCAGGCTGG
 ATGCCTCGGCAACTCCACGCATACTCGTGTGAAAATGAAATTGCGAAGTCCCATTAAACT

```

M_P_A_A_T_P_R_I_L_R_A_V_K_M_E_I_V_R_S_S_H_L_N_
TTCCAAACAAAAGTAGTAATTAGAATAACTTCTTGATGGCAGAAGAACAGATTTATAGAGT
F_P_N_K_S_S_N_L_R_N_K_L_L_* M_A_E_E_H_R_F_Y_R_V
TAAAACTTCATGAATATGTGACCAGAGAAATTGCTGGCTACTGGTCTGAAGAAGTCAACTAAAAA
K_T_F_M_N_M_*
CTAAAATTAAATAATCGTATTCTAAACTAAACTATAATATTTTACTTGTGATAAACGATATAACTG
AAAAGCCAATTGATTCCGTGGCACCCATTTCATAAACGAAACCAGATATTGCCATTAAATCCGT
GCCACAGGCGAACAATTCTGTTGCCTTCATAACGTTAATTGCAACAAATTGGCTG

```

Para el gen 2L_120, el programa Augustus Gene Prediction predijo una estructura compuesta por 2 exones de 2373 pares de bases el primero y el segundo de 45 pares de bases, y 1 intrón de 62 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido SVTCLENVSLR con una probabilidad de $p=0.009$ y un valor $E=2.74974465259169e-05$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 19 sORFs. Se pueden observar repeticiones en tandem y desplazadas. Los sORFs decimoctavo y decimonoveno son repeticiones desplazadas de los sORFs quinto y sexto. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de un péptido definido por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2L_122



AACTCCACAAATCTCGCAGCAGGCAACGGTTTGAAATATGTCAGCCAGTTGATTCTGTAGGAATAT
 ACTCAAGACAAATCACATTATTCTGAACCTGCTCTGGCAAATGATATTAAATATCAATATGTTAGC
 M_I_F_N_I_N_M_F_S
 TCGTTATGACATGAGGGGTTGTTGCTATGCTAATACAGCCTGATTGCTCTCGTAAATTTAATGGGG
 S_F_M_T_*
 TTTCTAGTTAATGTTAATACTAGTTAATAAAAATTAAAGCCATAGAGCTCTCAGGGCTCAAATA
 GGGCCATATACTCAGCTCAGTTGATGAGGCTGCTACTGAGTTCTGCTCTTGATTCACAAATGAG
 M_R_L_L_L_S_S_V_S_L_Y_S_N_K_*
 ATTAAAATCAAACATTTGAATAAAATACCCTGTTGACTTTTCTATCAATTCACTACCAGGCCAATCA
 GAATCCACATAACCAATAATTTCATAATGCCAAGTTCTTTAAAATCAATTCAATCGATAG
 TGCCCTCAAATATCTAAGAACTCTTTAAGTTCTGCCATAATTGGAGTTATTTGCTACTATATCT
 GCTCAAGATATTACTGCAGTAGTTAACATGGCGTGTACAAAGCATTGACATTAAACATCCTATG
 M_Y_I_K_H_P_M
 AGGCTACGGCATGGGTATTACAGTCTCATCTGAATTAAGTAATTCTATAATTATTACTAGGTAAG
 R_L_R_H_G_V_L_Q_S_S_S_E_L_S_N_S_*
 M_G_Y_Y_S_L_H_L_N_*
 GAGTACTAACTGCATTACAATTTCATGTTAAATTACTAAATTCTTTAACATATGCAGATTGGC
 M_L_N_L_L_K_I_F_F_N_I_C_R_L_A
 M_Q_I_G
 TTAAATAGATTTCATGCATCTCATCTAATTCAATAAAATGTTTATTCATTTAGGTCACT
 *
 L_N_R_F_Y_L_H_A_S_L_S_*
 M_H_L_Y_P_N_S_N_K_M_F_Y_F_I_*
 CATCCTAAACTTTCCATTAACACCTTGAAGTTATTCTTGTCATATCTCCTGTAGCTATAACC
 ACATCATCTACATATAATAACATATGTTTCAATTGATGTTACCTTGCTAAATATATACAGC
 M_F_S_L_M_L_P_L_S_K_I_Y_I_Q
 GATCAACTGAAGAGTTACAAACTCACACTCTTCAATGCTGCTCAAATACTTCAAACCAGCATCTAGC
 R_S_T_E_E_F_T_N_S_H_S_F_N_A_C_S_N_T_S_N_Q_H_L_A
 M_L_A_Q_I_L_Q_T_S_I_*
 CGCTTGCTTGAGTCCGTAAATTGCCTATTCAATTACACACATTGTCACTATTACACGATATACCTGA
 A_C_L_S_P_*
 GGAAGTCTCATATAATTCCCTTTAACGTGCCATTAAAGAAAGCTGTTTACATCCATTGATGGA
 M_D
 CTTCAAGTTACTGTATTGCTAATGACAATATAAATCGGAAACTTGAAATTCTAGCTACAGGAGCAA
 F_Q_V_I_L_Y_C_*
 TGTCTCTCATAGTCTATTGGTATTTGAGTGAATCCTCGCAACCAATCTAGCTTGATCTAATT
 M_S_L_H_S_L_F_G_I_F_E_*
 GGATTCCAAGTTCTATTATAACAGAAAATACCCATCTGCTATCTACAATATTGTTCTCAGGCC
 TTTTGTAATTGTCAGTATTATAATTGAGCATTAACTCTGATTGATGGCTTCTCCCAAGA
 M_A_S_S_Q_E
 AGATTATCATCCCTATATTGAATTCTACAAATGAATTGGACATCATTAAATATAGTGTGAGCATT
 D_L_S_S_L_Y_*
 AGAACAACTTATTAGACTATTATCCTCTTCATTATAGGATATCTGAGGCTTAGTCTTAATCTC
 CTCTCTATTATAATTCTATGCCATCTTCTAGGGATTATCAATTCAATTCTTTAAGTGTC
 M_P_S_F_L_V_G_L_S_I_P_I_S_F_K_C_S
 TGCTGTTCACTTCCCTACTCTCATTGGGTTGCTGATCCCTACTTCAATTCAAGGTGATCATCTCG
 A_V_S_L_S_L_S_F_G_L_P_D_P_L_L_S_F_R_*
 TTTCTTTCTACTCTCATTGAGAAAATATTATTACTCTTCAATTCTGTTGATTATTTCTACTCT
 CGCATTCTACTCTCATTGGAAATTCTGTTGATTATTTCTACTCTGTCATTGGAAAATTATT
 TTCACTTCTACTATCTCAGGAATTGTATGTTGTCGCTTCAATTCTACTCTGTCATTGGAAACTCT
 TGTATTATTTCTACTGTCATTGGAAAATTATTCTACTCTGTTGATTATTTCTACTGTCATTGGAAATT
 TGTGTCGCTTCAATTCTACTCTCATTGGAAACTCTGTTGATTATTTCTACTGTCATTGGAAATT
 TTATTCTACTTCTACTATCTCAGGAACACTGTTCAAATTAAACAGCTCTAGAATTAAACCATA
 TGGTTCATCGACAACACATCTCGGACAATAATTTCATTCAGCATTCCACAACCTAAACC
 ATTGGGTTCATGCCACAAAAATACTTTAAATGATTATCATCAAACATTCCATTGTTGTTAATA
 M_I_Y_H_Q_T_F_L_V_C_F_*
 TGCACATAAACAGTTGCACCAAACACTCTCAAATGTTAAGTATGGCTTCTATTGTGCCACATCT
 M_H_I_N_S_C_T_K_H_S_Q_M_F_* M_A_S_Y_C_A_T_S_H
 ATGGGGTCTTGAACATCAACAAAGTGCCTGCTGAGAATTCTGTTGATTAAATAAGTAGCAGTTAATAC
 M_G_S_L_N_Y_Q_Q_V_L_C_*
 TGCTTCGCCCCAAAAGCTTTATCTAGCTTGCACCAACTAACCATGGTCAGCTTTCCGTAATGGTT

M_V_R_A_F_S_V_M_V
 CTTATCATTCTCTCAGAACACCATTAACGTGAGGTGTATGTCGACTGTTAAGTATAAGAAATTCCCTT
 L_I_I_L_S_E_T_P_F_N_*
 TCTTAACACAAAATTGTCTCATCTCATTTGACAAGTATTCTACCATTGTCAATGTATAAGTACACAAC
 M_Y_K_Y_T_T
 CTTAAATTAAAATGAGCTTCACTCTGGCTACAAAATCTGAAACATGCTAAACACATCAGATTATAT
 F_K_L_K_*
 M_S_F_T_L_G_Y_K_I_L_K_H_A_K_H_I_R_F_I_
 M_L_N_T_S_D_L_Y
 TTAATTAAATAAGTTACACAATAATGTGTAAACTGATCAACAAAGATCACAAAATAATTTTATCATCTA
 F_N_*
 L_I_K_* M_C_K_L_I_N_K_D_H_K_I_I_F_I_I_*
 AAGTAACTGGAGTAATAGGCCACAGACATCTGAGTGTACTACAAAAGTGGCTTTAATATGGGTCTT
 M_G_L
 ATCTTCATTGTTAAAAGGAAGTCTGCCTGTTACCATTAAACAGGGTCACAAATTTCACATGAT
 I_F_Q_L_F_K_R_K_S_C_L_F_T_I_* M_I
 AACTCTAAGTTGTTAGAAGACTTGATCACTAAACATATTCTCGTTTATTCTAATAATTGCCAT
 T_L_S_C_L_E_D_F_D_H_*
 CGCTTATATGCCAACCTCTCATGCCATAAACGAAAATTATTTTATGCTTAGCATTAGAATATGC
 M_L_S_I_Y_R_I_C
 TTGAAAATTGATCACAGGTACATTGTTAACATACCTGAATTGGACAACCATTAAACCCATTTCGAA
 L_K_I_D_H_R_Y_I_V_*
 ATGGTTACACCGCTTTGTCAAATCGATCGACATTCTGCCTTGGAGACGCTTACGGACATCAAAT
 TACCAAGCTTACAAAAGAGTACATCCTCAGTGTAACTCATGGTCATTCCGTAGTCGGACAAT
 ACCACGCTTAGTGGCATAAATAATTGCCCTGCTGGCCACTGCAATCTAAGTGGAGGCACACCTCC
 ACACGTGCGGTATACAGCGACTCATCATTATAAGATGGTCACTAGCACCAGAATCAAGGACAAACCGC
 M_V_T_S_T_R_I_K_D_K_P_A
 AGTTGTCCATCACTGAAGTATTATTCACTTCTTACCATAAACGCAATGCCGTGTGATGTTGCAGTTG
 V_V_H_H_* M_L_Q_F
 AACTTGTTTTCATTTCTTATTATTAAATATTCTTATAATGGAAACAATCTTTTAATG
 E_L_V_F_H_F_L_Y_F_Y_Y_L_I_F_F_Y_N_G_N_N_L_F_*
 M_E_T_I_F_F_N
 TGGCCTCTGCCACAGTGGTACACTGACTTATACTTGAATTCCCTGAATATTTCTTGGTT
 V_A_F_S_A_T_V_V_T_L_D_F_I_L_*
 TAGTTACCGATTAAACAAATTATTAAATAGTGTATTATTGTTGTCACGATCGCCTTACAAAC
 TTTCTGCTTGTATCGTTGGTCATTAAATTTAATTCTGATCCAGCAATCTATTTCACAAAC
 GCCAATGTCAAATTCTCAGATAATGCTCTATCGCTGAATAATTCCATCGAACACAGAAGGCAATG
 M_S_N_F_L_Q_I_M_S_L_S_L_*
 TGATCAGTAGATGAGAAATTATCCATCTCTTCTATTGGCACCAGCTGCCAACATTCACTTATAAG
 M_R_N_F_I_H_L_F_Y_F_C_T_S_C_Q_Q_F_T_Y_K
 TTCGTAAAAATATGAAATGGCTTAATAGTGCACATCTCACTCGATAGCTCAGAGAAAGCAAACGTTT
 F_V_K_N_M_K_M_A_*
 CGCAGCGCCAGTTGCGACGCCAACCTTTCGTTCAAAACGGCGTCAAATTCTAAGAATCTGACGCG
 CGTAATGTCGCTTGTGCAAATTAAAAACGAGTCGCTTAGGTACTCTATTATTGTACTTTGCACA
 ACGCTGCTTTCCAGGAGTCATCTACCTCGTAGGCATTAACCATCAACTACTTAAGCACATCT
 TGCTCGGCTAAAGAGGCCATTAAATTCTAAATTCCAAATCGCGTACTTCTCGCCATCAAACGGCTTAATAT
 TACGTTAGCCTGTCCTTCACTCAAATTCTGAGAAGGAAATAATTCAAAAGAATGTGAAAAAAA
 GCTATTCAAGAATGTGAAAAAAATGCTATTTCACAATTTCACAATTCTTAATTCAAAATT
 M_L_F_H_N_L_F_S_Q_S_L_I_H_N
 TAATTGTTATTAGGCATGGACTGGCCATAACCTGTTGTAATTATAATTATTCCTTCTTAAT
 L_I_V_Y_*
 AAATAAAATAATAGTCAAGTTATGTTGAGTTATGATTATTTAAGTTATTCAACTGCAACAC
 M_F_E_F_Y_D_L_Y_F_K_L_F_Q_L_Q_H
 CAGCACCAACGACCTACTCACAGAAAAACGTACAAGAAGGAAAGAAGGAAATAAGAGTGGTATTCTCT
 Q_H_H_D_L_L_T_A_K_N_V_Q_E_G_K_K_E_*
 CACAATATGTTTATGGCATAAAAGGTGTGGCATTCTCATATCAAATATAAAGTAGTGTGTTAACGTTA
 TTTTGTTAGGTTGAATAGTATATTCAACAGCAGTAATTAAATTCTCAAAGATTCTCTATCCTT
 TGGCTCAATAGCCCACGACAGAACAAATAAGAGAGACTCATTGTGCACTTAATGCACTGCTAACACA
 M_H_C_S_T_T
 ATTGTTTATACACATTGTTAATTAAATTAAATTCTCAAAGATTCTCTATCCTT
 I_C_F_I_H_I_C_I_*

AATCTGTTCTCTCGGTAAACGACATTCGTCAAGGGAAAATGCCTCGCTGCTGCACTACTTGCA
 M_R_S_A_A_A_L_L_A
 GGTATAGAAAGCACCTGCAGCGAAGTAGAAAGTTAGGAATAAAAGGTCTATTGTTTCCACA
 G_I_E_S_T_C_S_A_N_L_E_S_*
 TCCAAGTCTCGCTAATGAAGACTTTCTATTGCTGTATTTTTAAATTCATCATACGCGTAAGGC
 M_K_T_F_S_L_L_Y_F_F_*
 TGAGCAAGTTGAAGAGGAATTTCGGGGAAAAGAATTTCATTAAAGTATAGGAGAATCTGTTCG
 GAATTGGATAGCCGGCTATGCGCTACTTGTAGGCAGTTGTGAAAGTAGCTAAA
 M_S_L_L_V_G_V_C_C_E_K_*
 ACTTAGTTCTCCATTGGTAAATAAAATTCTTAATTTATACAGTATAATTGCTTAGCTGCAT
 CGATAGTTAGCTGCATCGGCAAGATATCTGCATTATTTCATTGGTGAATAGAAAATTGTA
 CGAAAATTACATACGTTGCTGCATCGCAGATAACAGCCTTTAACTTAAGTGCATATCAGCTGTT
 TTTTGCCAATTCAATGAATATCATCAAAGTTAGCTGCGCCATCTATGAATCATTTGCA
 M_N_I_I_K_V_S_C_A_I_Y_E_S_F_L_H_I_*
 AGATGGCAAGAATGCCAAGTCGTTCAGTATCTGCGCATGTCGTTTGCTTGTGATT
 M_A_R_M_P_T_R_F_S_I_C_A_C_P_F_L_F_L_L_*
 M_S_V_F_V_F_A_L_I_V_I
 TTTGTGTTTGTCTTATGACACAAAGTTAAATGGGAAAAGCGTGTGGACTAAC
 F_V_F_L_F_L_M_T_Q_S_Y_*
 CTAAAGGAAAAGCTCAAATAATCGAGTTAGTGACCAACAAAGTGGACAAAAGGAAATTGCA
 TCAAATGCGACAGATCCACAGTCACCGCATTTCACAAAAACAAATGAAATTCA
 M_R_Q_I_H_S_Q_P_H_F_T_K_N_K_*
 M_K_F_M_K_L_W_S
 GTCAGGTTAAAAGAAAGCGTCAAAGAAAAGGAGCGCACGACTTAGTAGAAGAAC
 R_Q_V_*
 TCGGACAGCAGGAATCAAAGAACGTAATTCTGACCGGCACGT
 CATATTAGCAAAAGCGAAATTTCACGGCCTTGAACCTGACGCCAGCTGGCTTGGCG
 CTTAATTCAAAATTAAATA
 ATTTAGGCATGGACTGGGCCATAACCTGTTGAATTATAATT
 ATTCAAAATTCAACTGCAACACCAGCAC
 M_F_E_F_Y_D_L_Y_F_K_L_F_Q_L_Q_H_Q_H
 CACGACCTACTCACAGCAAAACGTACAAGAAGGAAAGAAGGAATAAAGAGTGGTATT
 CTCTCACAAAT
 H_D_L_L_T_A_K_N_V_Q_E_G_K_K_E_*
 ATGTTTATGGATAAAAGGTGTGCCATT
 CATAATCAAATATAAAAGTAGTGTGTTAACGTTATT
 TTGCTTCTCTCGGTAAACGACATTCTCGCAAGGGAAAATGCCTCGCTGCA
 M_H_C_S_T_T_I_C
 TTTATACACATTGTATTAAATTAAAATATTCAAAACTTAAAGGTGCATTAGGCC
 CAAATCTG
 F_I_H_I_C_I_*
 TTCCTCTCTCGGTAAACGACATTCTCGCAAGGGAAAATGCCTCGCTGCA
 M_R_S_A_A_A_L_L_A_G_I
 GAAAGCACCTGCAGCGAAGTTAGAAATAAAAGGTCTATTGTTTCCACA
 ACTTCCAAG
 E_S_T_C_S_A_N_L_E_S_*
 TCTCGCTAATGAAGACTTTCTATTGCTGTATT
 TTTAAATTCA
 TACACGAGGAGTACGCGGCTATGCGCTACTTGTAGGCAGTTGTG
 AAAAGTAGCTAAACTAG
 M_S_L_L_V_G_V_C_C_E_K_*
 AGTTGAAGAGGAATTTCGGGGAAAAGAATTTCATTAAAGTATAGGAGAATCTGTT
 CGGAATT
 TTTGATGAGGAGTACGCGGCTATGCGCTACTTGTAGGCAGTTGTG
 AAAAGTAGCTAAACTAG
 M_S_L_L_V_G_V_C_C_E_K_*
 TTCTCCATTGGTAAATAAAATTCTTAATT
 TATACAGTATAATTGCTTAGCTGCATCGATAG
 TTAGCTGCATCGGCAAGATATCTGCATT
 ATTTCATTGGTGAATAGAAAATTG
 TACGAAAA
 TTCATACGTTGCTGCATCGCAGATAACAGCCTTTAACTTAAGTGC
 ATCATATCAGCTGTTTTG
 CCAATTCAATGAATATCATCAAAGTTAGCTGCGCCATCTATGA
 ATCATTTGCA
 M_N_I_I_K_V_S_C_A_I_Y_E_S_F_L_H_I_*
 M_C
 AAGAAC
 GCAACTCGTTCA
 GAGTATCTGCGCATGTCGTTTGCTTGTGATT
 GTGATT
 M_R_M_P_T_R_F_S_I_C_A_C_P_F_L_F_L_L_*
 M_S_V_F_V_F_A_L_I_V_I_F_V
 TTTTGTTCTTATGACACAAAGTT
 ATTAAATGGTAAAACAAGCGTGTGGACTAAC
 ACTAAAG
 F_L_F_L_M_T_Q_S_Y_*
 GAAAAGCTTCAAATAATCGAGTTAGTGACCAACAAAGTGGAC
 AAAAGGAAATTG
 GCGACAGATCCACAGTCACCGCATT
 TACAAAAACAAATGAAATT
 CATGAAGCTGTGGT
 CGCGTCAGG
 M_R_Q_I_H_S_Q_P_H_F_T_K_N_K_*

M_K_F_M_K_L_W_S_R_Q
 TTTAAAAGAAAGCGTCAAAGAAAAGGAGCGCACGACTTAGTAGAAGAACCTTATACATTGGTCGGA
 V_*
 CAGCAGGAATCAAAGAACGTAATTCTGACCGGCACGTATATTAGCAAAAGCGAAAGAATTTCGCAAA
 AATTAAACGACGCCATTGAAACCTGACGCCAGCTGGCTTGGCGTTAACATTACAATTAAATTGTTATT
 AGGCATGGACTGGGCCATAACCTGTTAATTATAATTATTCCTTCTAACAAATAAAATAAAAT
 AGTCAAGTTATGTTGAGTTATGATTATATTAAAGTTACTGCAACACCAGCACACGAC
 M_F_E_F_Y_D_L_Y_F_K_L_F_Q_L_Q_H_Q_H_H_D
 CTACTCACAGCAAAACGTACAAGAAGGAAAGAAGGAAATAAAAGAGTGGTATTCTCTCACAAATATGTT
 L_L_T_A_K_N_V_Q_E_G_K_E_*
 TATGGCATAAAAGGTGTGGCATTATCAAATATAAGTAGTGTGTTAACGTTATTGTTAGGTT
 GAATAGTATATTCAAACAGCAGTAATTAAATTATTCCTTCTATCCTTTGGCTCAATAGC
 CCACGACAGAACAAATAAGAGAGACTCATTTGTGCACTTAATGCACTGCTAACACAACAAATTGTTTATA
 M_H_C_S_T_T_I_C_F_I
 CACATTGTATTTAATTAAATTTCAAAACTTAAGGTGCATTAGGCCCTAATCTGTTCTC
 H_I_C_I_*
 TTCTCGGTAACGACATTCGTCAAGGGAAAATGCGCTCGCTGCACTACTGCAAGGTATAGAAAGC
 M_R_S_A_A_A_L_L_A_G_I_E_S
 ACCTGCAGCGCAACTTAGAAAGTTAGGAATAAAAGGTCTCATGTTTCCACAACCTCCAAGTCTCG
 T_C_S_A_N_L_E_S_*
 CTAATGAAGACTTTTCATTGCTGTATTAAATTTCATCATACGGTAAGGCTGAGCAAGTTG
 M_K_T_F_S_L_L_Y_F_F_*
 AAGAGGAATTTCGGGGAAAAGAATTTCATTAAAGTATAGGAGAATCTGTTCGGAATTGGAT
 GAGGATATAGCCGGCTATGCGCTACTGTAGGCGTTGTTGAAAGTAGCTAAACTAGTTCTC
 M_S_L_L_V_G_V_C_C_E_K_*
 CATTTGGTAAATAAAATTCTTAATTATACAGTATAATTGCTAGCTGCATCGATAGTTAGCT
 GCATCGGCAAGATATCTGCATTATTTCCATTGGTGTGAATAGAAAATTGTACGAAAATTCTATA
 CGTTGCTGCATCGCAGATAACAGCCTTTAACCTAAGTGATCATATCAGCTGTTGGCAATT
 TCAATGAATATCATCAAAGTTAGCTGCCATCTATGAATCATTGATATCTAAAGATGGCAAGAA
 M_N_I_I_K_V_S_C_A_I_Y_E_S_F_L_H_I_* M_A_R
 TGCCAACTCGTTCACTGCGCATGTCGTTGCTTGTGATCGTGTGATTTGTTGTTG
 M_P_T_R_F_S_I_C_A_C_P_F_L_F_L_L_*
 M_S_V_F_V_F_A_L_I_V_I_F_V_F_L
 TTTCTTATGACACAAAGTTAAATGGTAAACAAAGCGTGTGGACTAACACTAAAGGAAAAG
 F_L_M_T_Q_S_Y_*
 CTTCAAATAATCGAGTTAGTGACCAACAAAGTGGACAAAAGGAAATTGTGCCAAGTTCAAATGCGACA
 M_R_Q
 GATCCACAGTCACCGCATTACAAAAACAAA
 I_H_S_Q_P_H_F_T_K_N_K_*

Para el gen 2L_122, el programa Augustus Gene Prediction predijo una estructura compuesta por 1 exón de 1187 pares de bases.

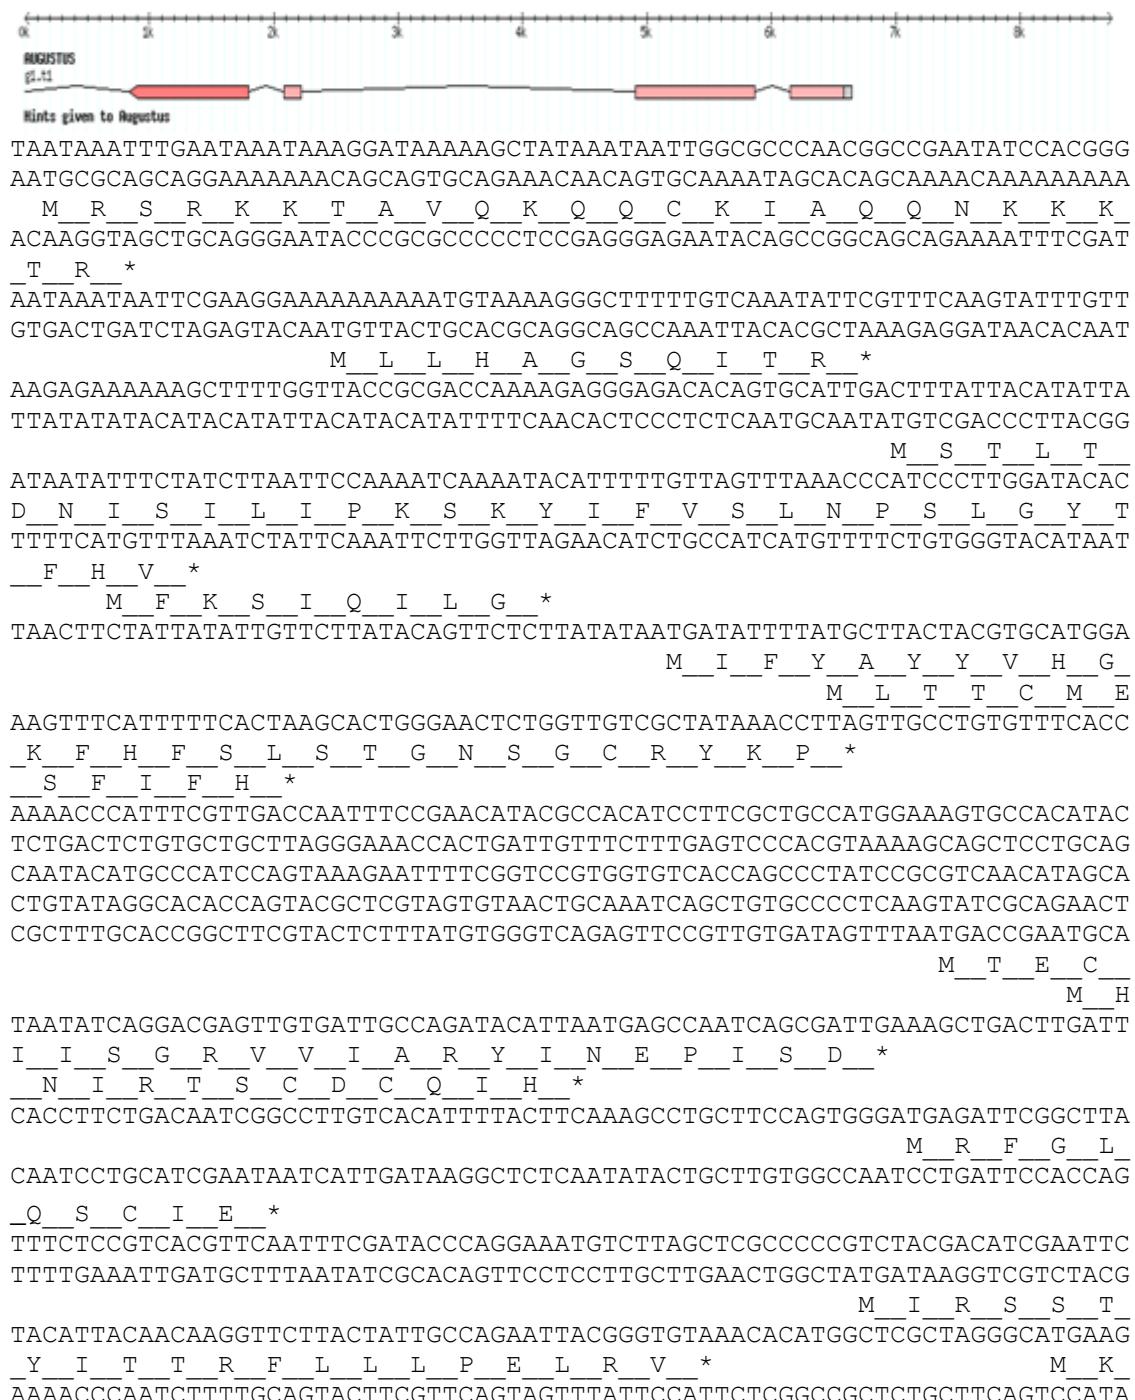
Se encontró acuerdo con espectros de masas para el péptido LFQLHQHHDLLTAKNVQEGK con una probabilidad de $p=0.032$ y un valor E=0.000340108579655668; para el péptido LLQMIPYQQMSTKMI con una probabilidad de $p=0.055$ y un valor E=0.000666173665229102; para el péptido LNLLKIFFNICR con una probabilidad de $p=0.054$ y un valor E=0.000310923654121335; para el péptido ASSQEDLSSLY con una probabilidad de $p=0.003$ y un valor E=3.23564926321861e-05.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 62 sORFs. Se pueden observar repeticiones. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 4 péptidos definidos

por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_39



K T Q S F A V L R S V V Y S I L G R S A S V H
 TATAGATTGTGTAACCTCAGCACCTCTTGATATCGTTATCGATGAATCCCTCTGGCTGCCTCATA
 I * M N P S G C L I
 TATACCGTTCGTAAGATCACCAATTCAAGTATGCAGACGAGACGTCCATTGGTCATGTAGAGACCGT
 Y T V S * M Q T R R P F G A C R D R
 TTTCCACGCCAAAGCAATTACTAATTAAATTGATGAGTAGCGTGCCACTGGTGAGAACGTATCCGTGAA
 F P P K Q L L I * M S S V P L V R T Y P *
 GTTAACGCCGTATCGCTGAGCGCACCCCTTGGACAAGTCGAGACTTAAACCTCTGACTTGCCTCATC
 TTGTTACGCTTCAGCTTCGACCAATTGGCTTCTCACCTGCCGGAAATCCACCAATGACCAGGTTT
 M T R F
 GTTTGACGTAGGCTCTCAAACCTCCTCTGCATTGAGGTTCTCCATTCTCAGAGTTCCATTGGTTCC
 C L H V G S P T P S A L R F S I L Q S S L W F P
 GCCTCCTTGACGCTTGGAGTTGGAACCTCATCCGTACTTGCCTTACCCCTCAGCAACACAGACTGG
 P P *
 AAGGTGCTGCATCTCCACAAGTTAACATCGGGAGAAGGTACTGCTTGCCCTGCCGTACACCATCATCC
 TGGTCGTTCTCAAATAACATTACGTACAGCAACACAGATATTCTCCTGATAGGATTGAACAGGCGAT
 ATCCCTAGAACATCAGAGTATCCAACAAATATTTCGCCCTCGCAGAAAACCTCCTTTG
 GGACTTGTTAACGACGATAGCCTCGAACCAATATCTCAGGTGGGACACATATGGCTCCTCAGTC
 M A S F Q S
 CAAGACTCGAACGGTGTACATCAGATAATGCTGACGTCTCAGCGCATTGCGTAGATAAGCAGCAGTAT
 K T R T V L H Q I M L T S Q R D C V D K Q Q Y
 TGATAGCTTCAGCCCAGTAGTGAGTGGCCACGCCTCGTGAATCATAGTCCTGCCATCTGACCAAG
 *
 GGTCGGTTAGCCGCTCCGCTACACGGTTTGTGGGGTGTGCGGTACCATCAATTGTCCTTTATG
 CGTTTCTGTCAGATAACATTGAAACGCTTACTAAATACTCACGCCGTTGCGCTCCTTATTGCTT
 TCAACTTCTTGGTTTCGCAAATGCTTAAACTCCTTGAAATTGGTCAGTATTTCATCTCGTCTT
 ATGAAATACACAAACATGTATCTGATTGTCATCTACGAAAGTGACAAAATAGCGTGCACCTCAAACAG
 M K Y T N M Y L D L S S T K V T K *
 ACGTCGTTGCATTGGACCACAGATATCACTATGCACTAGCTCCAGTACATCAATTGCGATTCCAGA
 GGCTTTGGAAACTCTCACACATATCTGCTTTGCGCAGCTCAAACAGTCATTTCATTGCGCCA
 CTTAAATATTTCTTAGTCCGAGTACCAATTCTGTTGATCATTGTTCAAGCTTGCAAGTTCA
 AATGACCGAATCTGGTGCACATTCTCATTAAATTGTCATGCAACGAAACATGCACTTCAACTT
 M T E S L V P L S H * M H F Q L
 TCTTCATTTGGAACATAACAAATCACTTGCAGTCAGCAATCAAACAAACTTATTCTTATCATT
 F F H F G T *
 TTTAAATTCGCGCCTGTTCAACAGACACACGAAATCCGTTCAATTGCTCGACACCGACATAA
 AGTTGCATTGTAATTCTTACAAAGAGTACGTGATCAATTCAAATGATGAGTTGCGCCAGGCTATT
 M M S C A R L F
 CACTGTACACGACCGTCAGCCATAATATACTTATTGCCAACCAAAAGAATGCGCTCTTATGCTCTG
 S L Y H D R Q P * M R S L C S L
 M L S
 AAGCTTTAAACATCGATCTCACCGCACAAATGAGCGTTGCTCTGAATCAAGGCACCATATT
 K L L N I D L S P H K *
 E A F K H R S L T A Q M S R C S *
 TTGGCAATTGCCAAGCTGTACAGTTGAGCAGAGCACAGCTTGTGGCCGCTGCACCACAGTTCAACA
 ATTAACCTGTTCTTCCCGTTAACAGTGTGCTGATTATTACTTGACACTCTTCTTAATGTCACCTT
 M S L F
 GCTTTTGTGCGACCGAATTCAAATGCACTTGTGCTTTGCAGAATGTTCTTAATTGCCA
 A F C F A D R I P N A L C S L F A E C S *
 M F L I C H
 TACGCCTTGCCTCCTTGTAATTAAACATTCAATGTGGCAACTCATCGCGCGTT
 T P L P F L L *
 TATTGCAACTACGAAACTTCAAACGATTCCGGAAACTGGACAACAGGAGAATACTCAGGACTTCT
 TGGATCACCAATTGAATTCTTAGTTCAACAGCCGACAAAATTGTTACATGACTCGAACAA
 M T R N N
 CTTCTGTTCAGACATTCTCATGTCAACAAACTGCTTAGCAAACATATACGTCGTGCCGGCCTGAGGG
 F C F R H S H V Q Q L L *
 AGTGTGGATTTCACTAAGTCTTGCCATGCCTCACAGCAGTCTCACAGTTTATATGGTTAATTG
 M P L Q Q S H S F L Y G *
 M V N L
 GATGTCTTAATGCATAGCATTATACTTGCTAATGCTTTGCGCTTGCCTCGCGTCAACAAAGCCTTAGCT

G_C_L_N_A_* M_L_F_R_P_S_R_R_T_K_P_L_A
 CAGCACTATCACTTCTGTTAACACACGTCCACACACCACCCCCATAATTCTGCATGAATTAAGAC
 Q_H_Y_H_F_R_F_*
 ACTCTTCATTTGTACAGCCCACGCACTGTAGTTCATCATCAAGTTCTATTGGTTATTGATGAA
 CTCATTTCCACTCGATAAGTTTCGATTAAATCCCTGAATCACAATATTAAAGATGCCAATATTCA
 M_P_N_I
 TAATTCTGTTAGAACTATTCACTTTATGTCCCGTGGCTGGGCCCATAACCCCCATTCTGTTCAAGTA
 L_I_R_L_E_L_F_T_F_M_S_A_W_A_G_P_I_T_P_I_R_F_K_Y
 TTTATTGTGACTGATCTAGAGTACAATGTTACTGCACGCAGGCAGCCAATTACACGCTAAAGAGGATAA
 L_L_* M_L_L_H_A_G_S_Q_I_T_R_*
 CACAATAAGAGAAAAAAGCTTGGTACCGCGACCAAAAGAGGGAGACACAGTGCATTGACTTTATTAC
 ATATTATTATATACATACATACATATTCAACACTCCCTCTCAATGCAATATGTCGACCC
 M_S_T
 TTACGGATAATATTCTATCTAATTCAAATACATTTGTTAGTTAAACCCATCCCTTG
 L_T_D_N_I_S_I_L_I_P_K_S_K_Y_I_F_V_S_L_N_P_S_L_G
 ATACACTTTCATGTTAAATCTATTCAAATTCTGGTTAGAACATCTGCCATCATGTTCTGTGGGTA
 Y_T_F_H_V_*
 M_F_K_S_I_Q_I_L_G_*
 CATAATTAACCTATTATATTGTTCTTATACAGTTCTTATATAATGATATTATGCTTACTACGTG
 M_I_F_Y_A_Y_Y_V
 M_L_T_T_C
 CATGGAAAGTTTCACTTTCACTAAGCACTGGAACTCTGGTTGTCGCTATAAACCTTAGTTGCCTGTGT
 H_G_K_F_H_F_S_L_S_T_G_N_S_G_C_R_Y_K_P_*
 M_E_S_F_I_F_H_*
 TTCACCAAAACCCATTCTGTTGACCAATTCCGACATACGCCACATCCTCGCTGCCATGGAAAGTGC
 ACATACTCTGACTCTGTGCTGCTTAGGGAAACCACGTGATTGTTCTTGAGTCCCACGTAAAGCAGCTC
 CTGCAGCAATACATGCCATCCAGTAAAGAATTTCGGTCCGTGGTGTACCAGCCTATCCGCGTCAAC
 ATAGCACTGTATAGGCACACCAGTACGCTGTAGTGTAACTGCAAATCAGCTGTGCCCTCAAGTATCGC
 AGAAACTCGTTGCACCGGCTCGTACTCTTATGTGGTCAGAGTCCGGTGTGATAGTTAATGACCG
 M_T
 AATGCATAATATCAGGACGAGTTGTGATTGCCAGATACTTAATGAGCCAATCAGCGATTGAAAGCTGAC
 E_C_I_I_S_G_R_V_V_I_A_R_Y_I_N_E_P_I_S_D_*
 M_H_N_I_R_T_S_C_D_C_Q_I_H_*
 TTGATTCACCTCTGACAATCGGCCTGTCACATTAACTCAAAGCCTGCTCCAGTGGATGAGATT
 M_R_F
 GGCTTACAATCCTGCATCGAATAATCATTGATAAGGCTCTCAATATACTGCTTGTGGCAATCCTGATT
 G_L_Q_S_C_I_E_*
 CACCAAGTTCTCCGTCACGTTCAATTGATAACCCAGGAAATGTCCTAGCTCGCCCCGTCTACGACATC
 GAATTCTTTGAAATTGATGCTTAAATATCGCACAGTCCCTCTGCTGAACTGGCTATGATAAGGTG
 M_I_R_S
 TCTACGTACATTACAACAAGGTTCTACTATTGCCAGAATTACGGGTGAAACACATGGCTCGCTAGGGC
 S_T_Y_I_T_T_R_F_L_L_P_E_L_R_V_*
 ATGAAGAAAACCCATCTTGCAGTACTCGTTAGTATTCCATTCTCGCCGCTCTGCTTCAG
 M_K_K_T_Q_S_F_A_V_L_R_S_V_V_Y_S_I_L_G_R_S_A_S
 TCCATATATAGATTGTGTAACCTCAGCACCTTCTGGATATCGTCATCGATGAATCCCTGGCTGC
 V_H_I_*
 M_N_P_S_G_C
 CTCATATATACCGTTCTGTAAGATCACCATTCAAGTATGCAGACGAGACGTCCATTGGTGCATG
 L_I_Y_T_V_S_* M_Q_T_R_R_P_F_G_A_C_R
 GACCGTTTCCACCGCAAAGCAATTACTAATTAAATTGATGAGTAGCGTGCCTGGTGAACAGTATC
 D_R_F_P_P_K_Q_L_L_I_* M_S_S_V_P_L_V_R_T_Y
 CGTGAAGTTAACGCCGTATCGCTGAGCGCACCCCTTGGGACAAGTCGAGACTTAAACCTCGACTTT
 P_*
 CCCATTTGTTACGCTTACGCTTCAGCTTCAACATGGCCTCTCACCTGCCGAAATCCACCAATGACCA
 M_T
 GGTTTTGTTGCACGTAGGCTCTCAAACCTCTGCATTGAGGTTCTCATTCTCAGAGTTCTTATG
 R_F_C_L_H_V_G_S_P_T_P_S_A_L_R_F_S_I_L_Q_S_S_L_W
 GTTCCGCCTCTGACGCTCTGGAGTTGGAACCTCATCCGTACTCTGCCTTACCCAGCAACACA
 F_P_P_P_*
 GACTGGAAGGTGCTGCATCTCCACAAGTTGAACATCGGGAGAAGGTACTGCTTGCCCTGCCGTCA
 TCATCCTGGTCGTTCTCAAATACAATTACGTACAGCAACACAGATATTCTCCTGATAGGATTGAACA

GGCGATATCCCTAGAACATCAGAGTATCCAACCAAATATTTCTTCGCCCTCGCAGAAAACCTCCT
 TTTTGTGGACTGTTAACGACGATAGCCTCGAACCAAATATCTTCAGGTGGACACATATGGCTTCCTT
 M_A_S_F
 CCAGTCCAAGACTCGAACGGTGTACATCAGATAATGCTGACGTCTCAGCGCATTGCGTAGATAAGCAG
 Q_S_K_T_R_T_V_L_H_Q_I_M_L_T_S_Q_R_D_C_V_D_K_Q
 CAGTATTGATAGCTTCAGCCATAGTGAGTGGCCGACGCCTCGTGAATCATCATAGTCCTGCCATCTC
 Q_Y_*
 GACCAGGGTTCGGTTAGCGCCTCGCTACACC GTTTGTTGGGTGTGGTACCATCAATTGTC
 TTTATGCCCTTCTGTAAGATACTTGAAACGCTTACTTAAATACTCACGCCGTTGCGCTCCTTA
 TTGCTTCAACTCTTGGTTTCGGCAAATGCTTAAACTCCTTGAAATTGGTCAGTATTTCATCTC
 GTCTTATGAAATACACAAACATGTATCTGATTGTCATCTACGAAAGTGACAAAATAGCGTGCACCTC
 M_K_Y_T_N_M_Y_L_D_L_S_S_T_K_V_T_K_*
 CAACAGACGTCGTTGCATTGGACCACAGATATCACTATGCACTAGCTCCAGTACATCAATTGCGATT
 TCCAGAGGCTTGGAAACTCTTCACACATATCTGCTTTGCGCAGCTCAAACAGTCATTATT
 GCGCCACTAAATATTTCTTACTCGAGTACCAATTGTTGATCATTGTTCAAGCTTGCAA
 AGTTCAAATGACCGAATCTGGTGCACATTCTCATTAAATTGTCATGCAACGAAACATGCACTTTC
 M_T_E_S_L_V_P_L_S_H_* M_H_F
 AACTTTCTTCATTTGGAACATAACAAATCACTTGCAAGTCAGCAATCAAAACAACATTATTCTTA
 Q_L_F_F_H_F_G_T_*
 TCATTTTTAAATCCGCCTGTTGCAACGACACACGAAATCCGTTCAATTGCCCTCGACACCG
 ACATAAAAGTTGCATTGTAATTCTTACAAAGAGTACGTCATCAAATGATGAGTTGCGCAGGC
 M_M_S_C_A_R
 TATTTCACTGTACCACGACCGTCAGCCATAATATACTTATTGCCAACCAAAGAATGCGCTTTATGC
 L_F_S_L_Y_H_D_R_Q_P_* M_R_S_L_C_M_
 TCTCTGAAGCTTTAACATCGATCTCACCGCACAAATGAGCCGTTGCTCCTGAATCAAGGCACCA
 S_L_K_L_L_N_I_D_L_S_P_H_K_*
 L_S_E_A_F_K_H_R_S_L_T_A_Q_M_S_R_C_S_*
 TATTTTTGGCAATTGCCAACGCTGTACAGTTGAGCAGAGCACAGCTTGTGGCCGCTGCGACCACAGTT
 CCAACAATTAACTGTTCTTCCGTTAACAGTTGCTGATTATTACTTGACACTCTTAATGTCA
 M_S
 CTTTCGCTTTGTTGCAACGAAATCCAAATGCACTTTGTCGCTTTGAGAATGTTCTTAAT
 L_F_A_F_C_F_A_D_R_I_P_N_A_L_C_S_L_F_A_E_C_S_*
 M_F_L_I
 TTGCCATACGCCCTTGCCCTCCTTGTAAATTAAACATTCAATGAGGGCAACTCATCGCG
 C_H_T_P_L_P_F_L_L_*
 CGTTTCTATTGCAACTACGAAACTTCAAACGATTCCGGAAACTGGACAACAGGAGAAACTCAGGACT
 TCTTCTGGATCACCAATTGAATTCTTACAGTTGCTGATTATTACTTGACACTCG
 M_T_R
 AAACAACCTCTGTTCAGACATTCTCATGTCAACAACTGCTTAGCAAACATATACGTCGTGCCGGTCC
 N_N_F_C_F_R_H_S_H_V_Q_Q_L_L_*
 TGAGGGAGTGTGGATTCACTAAGTCTTGCCATGCCTCACAGCAGTCTCACAGTTTTATATGGTTA
 M_P_L_Q_Q_S_H_S_F_L_Y_G_*
 M_V
 ATTTGGGATGTCTTAATGCATAGCATTACTGCTAATGCTTTCTCGCCTCGCGTCGAACAAAGCCT
 N_L_G_C_L_N_A_* M_L_F_R_P_S_R_R_T_K_P
 TTAGCTCAGCACTACACTTGTGTTAACACAGTCCACACACCACCCCCATAATTCTGCATGAAT
 L_A_Q_H_Y_H_F_R_F_* M_H
 TAAGACACTCTTCATTGTACAGCCCACGCACTGTAGTTCATCATCAAGTTCTATTGGTTATT
 F_Q_L_F_F_H_F_G_T_*
 GATGAACTCATTCCACTTCGATAAGTTCTCGTATTAAATCCGAAATCACAATATTAAAGATGCCGA
 M_P
 ATATTCTAATTGTTAGAACATATTCACTTTATGTCGCGTGGCTGGGCCATAACCCCCATTGCTTT
 N_I_L_I_R_L_E_L_F_T_F_M_S_A_W_A_G_P_I_T_P_I_R_F
 CAAGTATTATTGTGACTGATCTAGAGTACAATGTTACTGCACGCAGGAGCCAAATTACACGCTAAAGA
 K_Y_L_L_* M_L_L_H_A_G_S_Q_I_T_R_*
 GGATAACACAATAAGAGAAAAAGCTTGGTACCGCGACCAAAAGAGGGAGACACAGTGCATTGACTT
 TATTACATATTATATATGTCGGAGCGCAGCTTCGCAATTCCAGAAATTCTCTGTGATTTCAT
 M_S_E_R_D_S_S_H_S_R_N_S_F_C_D_F_I
 ATTCTGATGAAATTGTAATATTGCGTAAATTCTGTCGAGCGCTGCGAGAGGCACGAACAGCCTCTG
 F_*

CAGCTGAGTGAGGTCCGATCGAGTGGTCATAAATAGTGTAGAGAGATGA

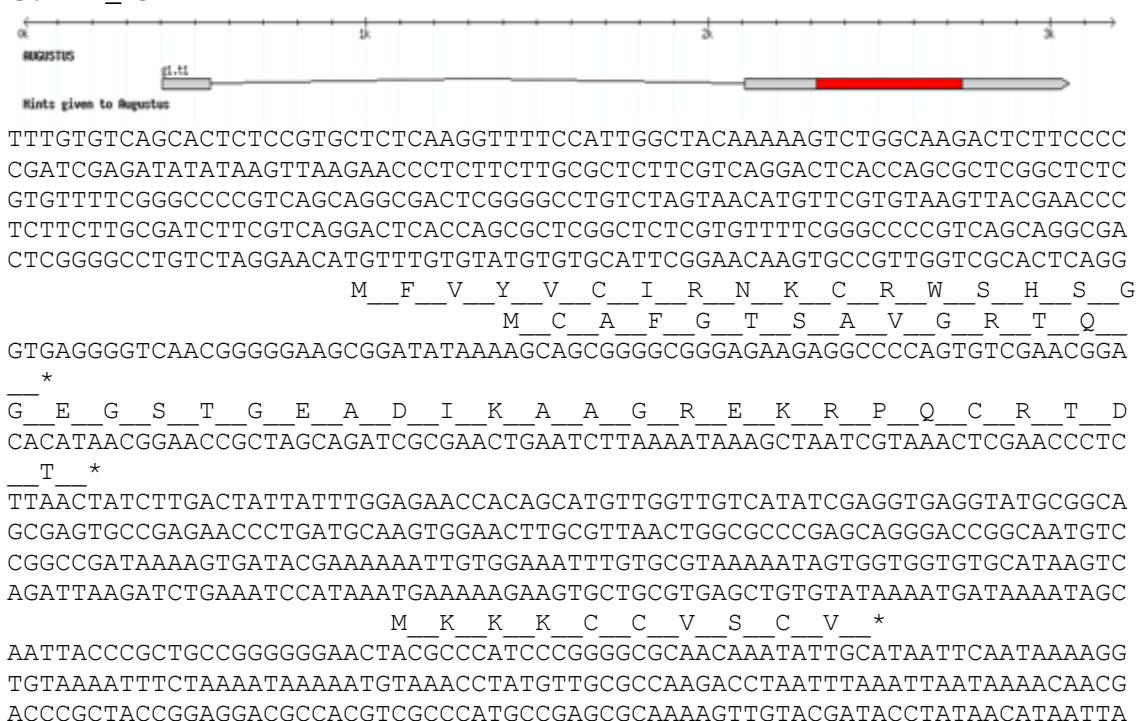
Para la región genómica 2R_39, el programa Augustus Gene Prediction predijo una estructura compuesta por 4 exones de 957 pares de bases el primero, 136 pares de bases el segundo, 957 pares de bases el tercero y 429 pares de bases el cuarto, y 3 intrones, el primero de 284 pares de bases, el segundo de 2689 pares de bases y el tercero de 284 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido STLTDNISILIPKS K con una probabilidad de $p=0.003$ y un valor $E=0.000847262945717522$; para el péptido MPNILIR con una probabilidad de $p=0.002$ y un valor $E=0.000568375656334029$; para el péptido SERDSSHRS R con una probabilidad de $p=0.096$ y un valor $E=0.000505724310511363$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 60 sORFs. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 3 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_43



M_P_S_A_K_V_V_R_Y_L_*
 AAACACGATCAACCCACTGC GGCGTACGGCTTGTGGAAAATTTTTCTCTCCTTGCCAATT CGC
 GAGTGCAAAAGATTGTGTATAATAAACCAATAATTACCATTCAGCAGTTAC TGCAGCAGTAC GAGT
 AATATGAGCGCCCAGAGTGATAAGGTGGTGTGGCAGCTGTTGGATAC GTTAAGTGGTGTGGAATGCA
 M_H
 CCCAAAAAAACCGCCCAACAAGTTGTGTGGCGGCCGTACCTTAGTAGGCAACCAGCAAAGGGATA C
 P_K_N_R_P_T_S_C_V_A_A_V_P_*
 TACGGAACCACCGTGCCCAGTGC GAAATAATTAGAGGTCAATAAAAAACTGTAACAGCACGCAC G
 CAAGGAAAAAATATTGCAAAATGGAATAGCGCACAAAATTGTATAAACACATGCACAACACCACAATT C
 M_H_N_T_T_I
 AAAGGAAAACAAGTATAGTACAATTCCCCAATTCCGAAACGAAATGAATAAAAATTCTCTACAATAC
 Q_R_K_T_S_I_V_Q_F_P_Q_F_P_E_T_K_*
 M_N_K_N_S_L_Q_Y
 ACTAATTCACTTTTACTTATCCAATAGAATATT CATGCTGTAGGGTACAACCTAACGACGAAA
 T_N_S_P_F_F_T_Y_P_N_R_I_F_M_L_*
 ACTAATAAAAGAGCATAAGGGTGAGT GAAATATT CATTAAC TTATTGCCATATTGCTAAATT TAG
 AGAAATAAAAGAAAAGCAAAGAAGAACAGATATTCTTTATCGGGTAAAACCGTTGTCTCACATT C
 CGTAAAGTAATAACAGTTAAAACCAGATCAGGAAAATTCCACAAATCTGATCTAAGAAATTGAGAC G
 TGGCTTCACATTAAAAAGAAACGCCAAAAGAATAACGAAAGTAATAAAAGTACGTTGGCAGCTA
 ATGAAATATTCCCCCATGCATACCC TATAAAAAAAACATTAGTTAAAAAAAAAAAAAAA
 M_K_Y_S_P_H_A_Y_P_I_*
 M_H_T_L_Y_K_K_N_I_S_*
 AAAAAGAATGAGTTAAGAAATACAAAAGAAATACAAAAAAACTATAAAAATAATA
 TAAAAAAATACAGATTATAAGAAATAAGAAATATAAAAATAAGTACACAAAAT
 GTACCGTACCCCCACACACTACGTAGTCTAGAACAACTTAGACGACCAGATATTACGAATTGTCTTT
 TGTAAGCGCGATTCTGCATCGCGC GCAAATCCGCTCACTGGACTGGCTGGGCTGGAAATGGG
 M_G
 TAGCTGGATCTCCAGATGCTGCTGATTGGAACGCCGTCTGGCCCGCAAGCGACGGCTCGAGGA ACTG
 S_W_I_S_R_C_C_*
 M_L_L_I_G_T_P_S_W_P_R_K_R_R_L_R_G_T
 CAAAAACTGGAGGAGGCTAGCTGTATCCCTCGGCTACTGAAGTAACCAACGAGTGGTTAAGCAAGTC GAC
 A_K_T_G_G_G_*
 GATGGAATGCTCCTCCGTACCAACTTCAACGGAACTCTAAGAACGGCTGCAGAGAACTACGACCTGATCG
 GCTCCTTATCATCCAATCGACAATGAGACGATAATGGTCAACGGTCAAAACTATTCCAGTTACTCGGT
 CAGTCATCTAATGGCGATGCCGGCGTGTGAGCCACATAACGCCAGCAACTTCAACTTTCTCTGGAA
 TACGTCCACGACGTGAGCATGAAGAATTGGAAAAGATGTCCAACATGGCAGTGAGCTACTAGCCTCTC
 TTCTCACCGAGGCGGCACTCGCAATCTGCATATTCTTAGGCTTTATTCCTATGGAAGAAGCTGATGTC
 CACCAAAAGGCATGCCGATGTCCCGAGATTGCCGAAACTTAGAAGCATTGGCCAAACCGAGCTGAAC
 AAGGCTCACTAATCTGCCGGACGCAGATCTGAGGGGGAGGAGTTAAGAACCCCTTTCTGCGCTCTC
 GTCAGGACTCACCAGCGCTCGCTCTGTGTTTCCGGCCCGTCAGCAGCGACTCGGGCCTGTCTAG
 GAACATGTTGTATGTGTGCATT CGGAACAAGTGCCTGGTCGACTCAGGGTGAGGGTCAACGGG
 M_F_V_Y_V_C_I_R_N_K_C_R_W_S_H_S_G_*
 M_C_A_F_G_T_S_A_V_G_R_T_Q_G_E_G_S_T_G
 GGAAGCGGATATAAAAGCAGCGGGCGGGAGAAGAGGGCCCCAGTGTGCAACGGACACATAACGGAACCGC
 E_A_D_I_K_A_A_G_R_E_K_R_P_Q_C_R_T_D_T_*
 TAGCAGATCGCGAACTGAATCTTAAAATAAGCTAATCGTAAACTCGAACCCCTCTTAACTATCTGACTA
 TTATTTGGAGAACACAGCATGTTGGTGTATCGAGGTGAGGTATCGGGCAGCGAGTGCCTGAGAACCC
 M_R_Q_R_V_P_R_T
 CTGATGCAAGTGGAACTTGC GTTAACTTATATGTATA
 L_M_Q_V_E_L_A_L_T_Y_M_Y_A_*

Para el gen 2R_43, el programa Augustus Gene Prediction predijo una estructura compuesta por 2 exones de 139 pares de bases el primero y 948 pares de bases el segundo, y 1 intrón de 1562 pareós de bases.

Se encontró acuerdo con espectros de masas para el péptido HNTTIQR con una probabilidad de $p=0.019$ y un valor $E=0.000167662151123091$; para el péptido NRPTSCVAAVP con una probabilidad de $p=0.081$ y un valor $E=0.000320259711550587$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 14 sORFs. Se puede observar una repetición desplazada. El sORF decimosegundo es una repetición desplazada del segundo sORF. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 2 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_54



_K_S_R_L_Q_K_D_N_S_*
 GTGGGGGTACGGTACATTTGTACTTATTTTATTTCGTTGGAAATTGGGGAAATTGTA
 CTATACTGTTTCCCTTGAAATTGTGGTGTGCATGTGTTATACAATTGTGCGCTATTCCATT
 M_C_L_Y_N_F_C_A_L_F_H_F
 TGCAATATTTTCTTGCCTGCGTGTACAGTTTTATTGATGACCTCTAATTATTTCGGCACT
 A_I_F_F_P_C_V_R_A_V_T_V_F_Y_*
 GGGCACGGTGGTCCGTAGTATCCCTTTGGCTGGTGCCTACTAAGGTACGGCCGCCACACAACCTGTT
 GGGCGGTTTTGGGTGCATTCCACACCACTAACGTATCCAACAAGCTGCCACACACCACCTTATCA
 CTCTGGCGCTCATATTACTCGTACTGCCGCAGGTAAACTGCTGAATGGTAATTATTGGTTATTATA
 M_V_N_Y_W_F_I_I
 CACAATCTTGCACTCGCGAATTGGCAAGGAGAGAAAAAAAATTCCCACAAGCCGTACCGCCGCA
 H_N_L_L_H_S_R_I_G_K_E_R_K_K_F_S_H_K_P_Y_R_R
 GTGGGTTGATCGTGTAAATTATGTTATAGGTATCGTACAACCTTGCCTGGCATGGCGACGTGGC
 S_G_L_I_V_F_*
 M_G_D_V_A
 GTCCTCCGGTAGGGTCGTTGTTATTAATTAAATTAGGTCTGGCGAACATAGGTTACATT
 S_S_G_S_G_S_L_F_Y_*
 ATTAGAAATTACACCTTATTGAATTATGCAATATTGTTGCCCGGGATGGCGTAGTTCCC
 M_Q_Y_L_L_R_P_G_M_G_V_V_P
 CCCGGCAGCGGGTAATTGCTATTATCATTACACAGCTCACGCAGCACTTTTCAATTATGG
 P_G_S_G_*
 ATTCAGATCTTAATCTGACTTATGCACACCACACTATTACGCACAATTCCACAATTTCG
 ATCACTTTATCGGCCGGACATTGCCGCTGTCGGCGCCAGTTACGCAAGTCCACTGCATCA
 GGGTCTCGGCACTCGCTGCCGCATACCTCACCTGATATGACAACCAACATGCTGTTCTCAAATA
 ATAGTCAAGATAGTTAAGAGGGTCGAGTTACGATTAGCTTATTAAAGATTCACTCGGATCTGCT
 AGCGGTTCCGTTATGTGTCGCTCGAGACTGGGCCTTCTCCGCCGCTGCTTATATCGCTTCC
 M_C_P_F_E_T_G_P_L_L_P_P_R_C_F_Y_I_R_F
 CCCGTTGACCCCTCACCTGAGTGCACGGCACTTGTCCGAATGCACACATACAAACATGTT
 P_R_*
 M_H_T_Y_T_N_M_F
 CTAGACAGGCCCGAGTCGCTGCTGACGGGGCCGAAACACGAGAGCCGAGCGCTGGTGAGTCACGAA
 L_D_R_P_R_V_A_C_*
 CATGTTACTAGACAGGCCCGAGTCGCTGCTGACGGGGCCGAAACACGAGAGCCGAGCGCTGGTGAG
 M_L_L_D_R_P_R_V_A_C_*
 TCCTGACGAAGAGCGCAAGAAGAGGGTCTTAACTTTATGTTACGTTCCATTTTTATGTGTACA
 M_L_R_F_H_F_F_L_C_V_Q
 M_C_T
 GAATGGCATTGGGCCAAACACAGTTCGTGTCCGCTGTTGCCAGTGTATTGCGTCCAGATGCA
 N_G_I_G_P_K_P_Q_F_V_F_R_C_W_P_V_Y_L_R_P_D_A_*
 E_W_H_W_A_E_T_T_V_R_V_P_L_L_A_S_V_F_A_S_R_C_A_*
 M_A_L_G_R_N_H_S_S_C_S_A_V_G_Q_C_I_C_V_Q_M_C_A_*
 *

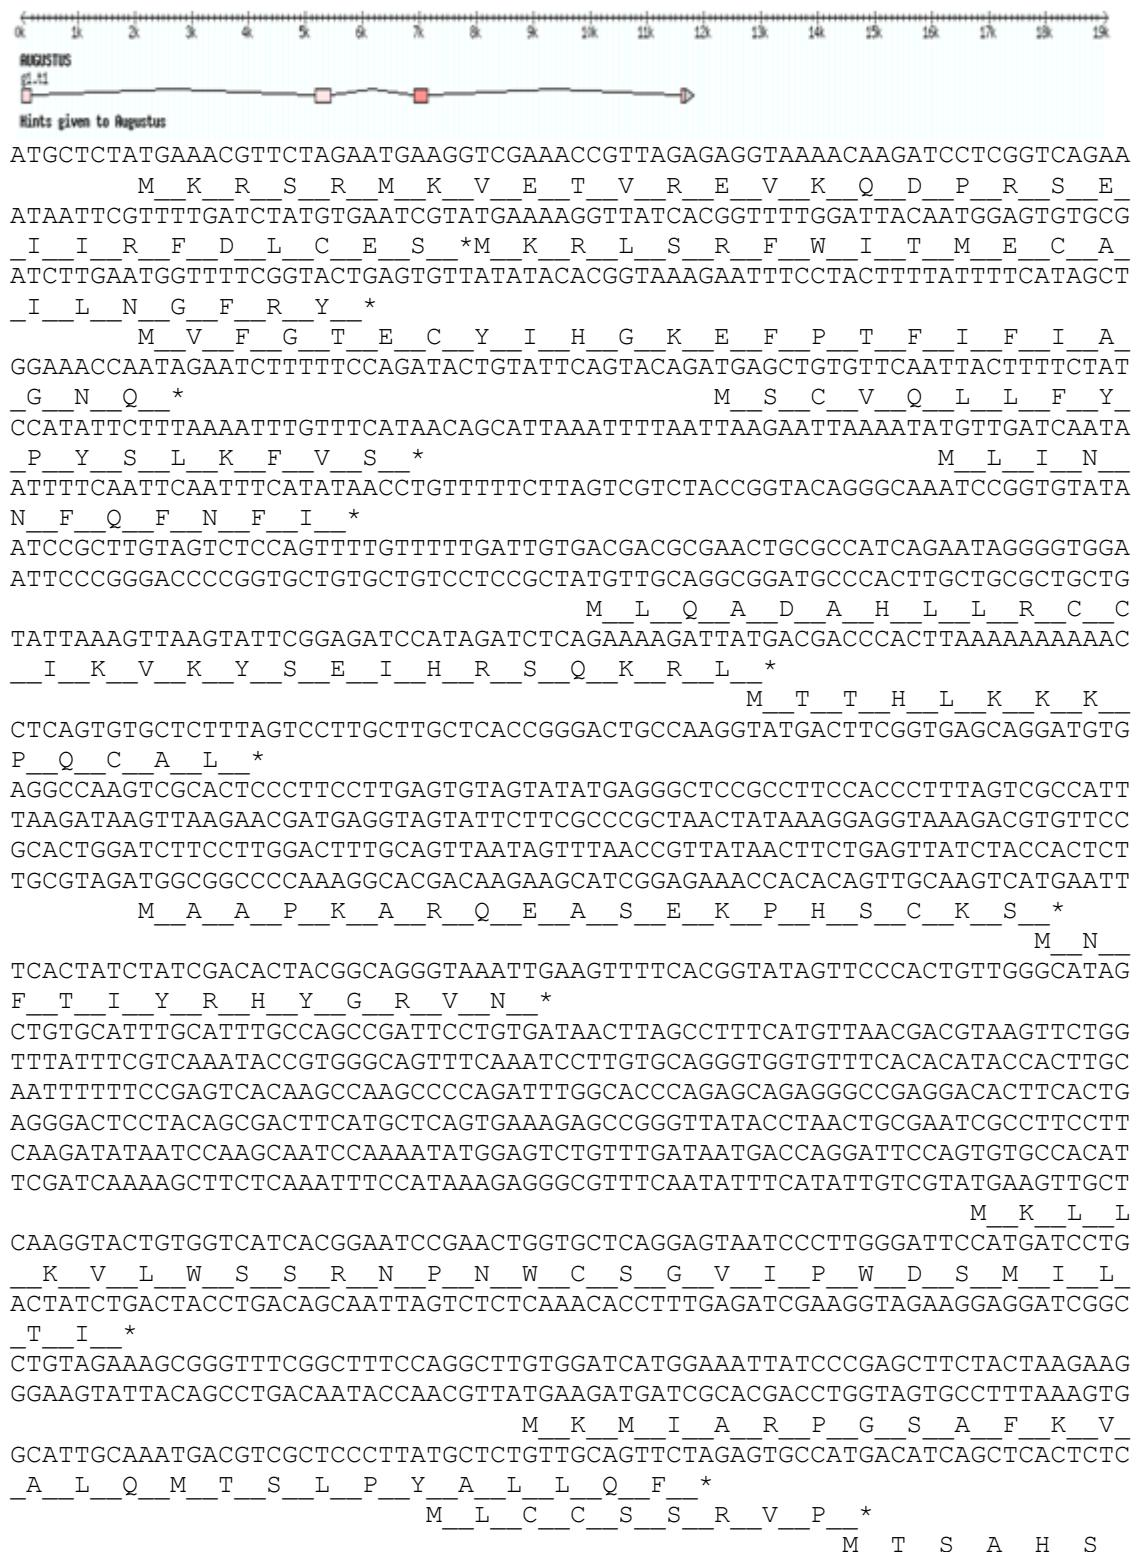
Para el gen 2R_54, el programa Augustus Gene Prediction predijo una estructura compuesta por 2 exones de 1752 pares de bases el primero y 132 pares de bases el segundo, y 1 intrón de 340 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido CPFETGPLLPPR con una probabilidad de $p=0.084$ y un valor $E=0.000609518336030885$; para el péptido SLGICRLR con una probabilidad de $p=0.008$ y un valor $E=0.000524605278366567$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 20 sORFs. Se puede observar una repetición desplazada. El sORF decimoséptimo es una duplicación desplazada del cuarto sORF. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 2 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_58



TGGGCTCAAACGGCGTGGTTGGAAGGTCCATCTGAATTGCTTGTCAGATGCTTATGAGTCTCTTCTAC
L_G_S_N_G_V_V_G_R_S_I_*
TTGCTGCTGACTGGCAAGCTTACATGGCTGAAGTCGCTCAGCGAGGGGAGCAGCGAATACATCCGCTTTC
M_A_E_V_A_Q_R_G_E_Q_R_I_H_P_L_S
CTCAAGTCAGTCGGCACCAAGCAATGTTGCTATCCATCAGTTGCGCCTCCTCGTCAACGCCCTTTGA
S_S_Q_S_G_T_K_Q_C_C_Y_P_S_V_A_P_S_S_C_N_A_F_*
M_L_L_S_I_S_C_A_F_L_V_Q_R_L_L
TTTCCGAGTTATCGGTGACGGCACGCCAGATATAGAACACTCAATCCGGACAGAAAGCTACAAA
I_S_E_L_S_V_T_A_R_A_R_Q_I_*
CTAGCAAGGTCAACAACCAGCAGAAAATCAGGATTCAAAGAAGACTGAACGCAGGGTATCGCAGCAGCAA
CGAATTGTACACTAGACTAAGTGAAGAAAGACTGAAATAAAATTCACTCTGATTCTGACCACTGA
TACATTCAAGTCCAACCAGAAATTCCCTCTACTCAGATACCTTTATGCGAAATTAAATCACTTTCTGG
GATATCATTAGCTGTTGGAAATAAACACAAACACTTTTACAATGTTGAGCAGTTGTGCGGTTA
GTGTGCCGTTAGAATGGGTGTGCCAAAAGATTATCAATTACAAGATTACAAGACTAA
M_G_V_P_K_R_F_I_N_F_T_R_F_Y_N_L_Q_D_*
TAATATTATGAAAAAAAGTGGCGTGGTTGGGCCACGAGTAACGGATATAACAAACCGGGATAAA
M_K_K_W_A_W_W_F_W_A_T_S_N_G_Y_T_N_R_D_K
TTTAAAAAAATGAAAATGAAAAACAAGAGACAACATTGCGGTTGAGCCTCACGACAACCACGACTTT
F_K_K_C_K_M_K_N_K_R_Q_H_C_G_*
ACTAGTCTAGTCGGGTTGTTATGAAGAAATTCCAATTCTGTTTCAATATCAATAACACTAATGGACGTT
M_K_K_F_P_I_S_F_S_Y_Q_* M_D_V
AATACAGACAGACAGGGAAATGCCTCTGAACATCCGAGAAAAGCACCATTGTCGATAACAAATAAGT
N_T_D_R_Q_G_K_C_L_L_N_I_R_E_K_H_H_V_R_*
M_P_S_E_H_P_R_K_A_P_C_S_I_T_N_K_V
TGGTGGAGCTCGTTGGAGTTGTTGCCCCATTACATAACATTGAAATTGATGAAAAAAATATCT
G_G_A_A_L_V_E_L_C_V_P_E_L_H_K_H_*
CTAACTTCTAGCGGCTCTAAATAAGATTGACTAACTATCGAAAGCACTTGACCATTACGACATCCC
CACCGACGCTCGACGAGCTACTCTTCCGGTGAACACCTCTACGCCCTGTTCCACTCTTTTG
GTATGGCCGGATCACATATGAACACCAGTTCTCGACGATTGGCTAGACGCAATTAAAGATCCATTG
M_A_G_S_H_M_N_T_S_S_P_R_R_L_A_R_R_N_*
ACTTCTGGACATGCACTGTCCTCGTCAAGTATGGTACAACCCATACTAGTCGGCTGCCCTGACGGCC
M_H_C_P_R_R_S_M_V_T_T_H_T_V_G_C_P_*
TTTCTTGGCTGTCCTGAGCAAACGCTCCTCTCGCATTGCGATTGCCATTATAAGTGGCGCTCTGCCCTAGTGC
ACTCCCTCGTCGTCAGTCCGTTGGTCCCTTATCGGAACGTAGTCCACGACATCGCGAATAATCTGTG
CACCCATGCGGTGCTCCTCACCAACCGGTTAGCTCGAAATCTATGCAACGATATAAAGTTCGCCGG
M_R_C_S_S_P_T_G_Y_S_S_K_I_Y_A_T_I_*
M_Q_R_Y_K_V_R_R
ACCAGGACAAACTCACATTCTCCTCTTAATCTGACGTGGGGGATTGCAAGTCTTGCGCGATAAAAT
D_Q_D_K_L_T_F_H_L_L_I_*
TTGTGGGGACGCGTTCATCTGTCATCTGTTGCTGGCTGCCACTACATTGATAGTACCTCAAGTGGGTT
AACTATCTAAGCACACTTGCGAACAGGAAGTAAATCGGCAGAAATCAAGCCCAGCGTCTGCATGTATAT
M_Y_I
ATCTCATCCGTTAAGAACGGCGATAGCTTCTTACTGGAGAAACTGTCGACGTAGTCTCCATGTA
S_H_P_L_R_N_G_D_S_F_F_F_T_G_E_T_V_D_V_V_F_H_V
GTGATACTCGTTGATCCGTGCTGCTTAACAAAGCACTCTCCGTCTCACATAATCGCGAGCAAGG
V_I_L_V_D_P_C_C_L_T_T_K_H_S_P_S_S_H_N_R_R_A_R
TGATCAGGCCGCTCCGAAAGTCATCATCTGCATCTCGTATATGTCGGCTCCAGACGATCGTCTCCTGTC
* M_S_G_S_R_R_S_S_P_V
CTCCATAAGAACCCCTGGAACCTCCCTCTGGCTGCATCAATAACTTGTAAAACAGATTATGTGATCTA
L_H_K_N_P_W_E_P_P_L_W_L_H_Q_Y_L_L_K_Q_I_M_*
GTCGGGGTCGACTTGGTTGGCGCCAGATATGTTTAATGATGAACGCGGCAAGGTAGTGGCCCG
AACTCCCTCCAGCACCGTTGCAAGGGGATGTCACCGTGGCACGTTGCTGCTCACGTAAGTGGTGA
AGTGTGTTGCGCGAGTTGCTATCCACAAACAGTCACCTCGTTGTCGCCCTGTTAGCTGTGGTGTGGTA
CAGAGTGCAGGATCAGGACCAGGTGGCACGATCGGTGACTATAGCTGAAGTGAACAGTGGAAATAAG
CCGGTAGCAGGGTCGACTCCGACTGTTGATATTCAACGGCAGTTGTTACGATAACGTCACTTATTTCG
GCTGTCAGTTCAAGAAATAACAAAGAGAGAGAGCTTAAGATTACCCATTCTCGCACAGATCAAGG
CCGCCGACCAGCATCCGAAGTATAGCTCGTGTGCGTCAACCGCAGCTTCTGATGTTAC
M_L
TTGTTAACTTATATAACTTATACTTATTGGCTCCGATAATTACCTAACATAGATCTTACGATTCTA
L_V_N_L_Y_N_N_L_Y_L_L_A_P_I_I_Y_L_T_*
TTCACTCTCTACTTGCCTTGTAGTTAAGGTACGCCACCTTATATACTCTATGAAACGTT

M_K_R
 CTAGAATGAAGGTCGAAACCGTTAGAGAGGTAAAACAAGATCCTCGGTAGAAATAATTGTTTGATCT
 S_R_M_K_V_E_T_V_R_E_V_K_Q_D_P_R_S_E_I_I_R_F_D_L
 ATGTGAATCGTAGGAAAAGGTTACGGTTGGATTACAATGGAGTGTGCGATCTGAATGGTTTCG
 C_E_S_*
 M_E_C_A_I_L_N_G_F_R
 GTACACGGTAAAGAATTTCCTACTTTAATTTCATAGCTGGAAACCAATAGAATCTTTCCAGGTACAG
 Y_T_V_K_N_F_L_L_*
 TATTCAAGTACAGATGAGCTCTGTTAAATTACTTTCTATCCATATTCTTAAATTGTTCTACAGC
 M_S_S_V_K_L_L_F_Y_P_Y_S_L_K_F_V_S_*
 ATTACATTTAATTAAGAATTACAATATGTTGATTCCACAGTCTCGGGTGGAGACGTGTTCTTCAG
 M_L_I_P_Q_S_S_G_G_D_V_F_L_S_S
 CTACGAATAGCAAGTTCTAAAAACTACAACAGTATAGTAAACACAAAGTGTAAAGTGCAGTT
 Y_E_*
 GCACAACAAATTATTGACTATAGTAAATTACTAAAATAATTATTCCATATTGTTCTGGTA
 ATTGTTATATGTGGACTTAGAACATGAATCAAACGACATACGTTCTCAGCGACAATGTGAACAAGACG
 AGCGCCGGCTCTTTACAACGCAACATGCATACTTTCTTCGTCTACCGCAAATCGGTGATCGAGC
 ACCCTCACCTCAACTAAGTAACTTGCCTCAGCGAACAGACAGCCGTTCTGCTCTCCCTCT
 CTGCCTGCTTCGGCTACAAGTCGTGGAGCGAAGAGACCGCCTCTCCTACCCGCTCTCGCAGCGCC
 AAACGACCGTCCGGTAACTGTAACACTGCAATAACGAGTCAGCTCACTGGCAACTGCCACAAC
 ATCAACTTCGTCAAGCGGCCACTAATTATCGCTGTGCCAGCTGTAATAATTCAAGCAGCACTGACCGTT
 TGCAACAAACAATAATGCACGTAAGAAGAACATCAAACAAAGCAGAAGTCGATTCGACTGTGCAGACTG
 GCATGGATCGCTACATCAAATCAAGAGAAAGCTCAGCCCTCAAACAAATAAGGCAGGTAATCAACCAA
 AATCAATCGAACCAACAACGGCAATGAAAACCTGCAGTAAATAATTCAAACCGATATGCTATCTGGCT
 M_L_S_W_L
 GATTCTGCGACCGAACAAACCAACGAAAAACGGTAGGGGAACCAAAAAAGACCAGGCCTCCACCAATT
 I_L_R_P_N_N_P_T_K_K_R_*
 TCATACGAGAACAAAGTACAATGCACTTGTAAATAAAACTCGTTGCTTGATTGGTGACAGCAAGTCCA
 CATTATCCCACTTAAAAAGGAAATATTCAATGAAATAAAACTACAGATCCAAACAGAACGACACCACGT
 ATAGTGAATAACCTAAATGATGCTGGTAAAACACTACACATACCAATTAAAAGTTGCAAAGGGC
 M_M_L_V_K_T_T_T_H_T_N_*
 TACAGGTAGTACTTAAGGCATTGAAGCAACAGTGACACCAGCTGAGATAATTGAGGCTCTGAAGGCCAA
 AAACTTTCTGCAAAGACAGCTTAATATTAAACAAAGACAAAGTCCCGACCCACTATTCAAATA
 GAACTCGAACCGAGAGCTCCAGGCACTAAAGAAAAACGAAGTCGACCCAAATACAAATTACAGTACTTGC
 TACATCGGAGGATACCGTGGAGGAGCCGCACAAACGTATCAATCCAGTTCAATGTAATTGCAAGA
 ATACGCCACACCAAGGCATACTGCACCCCTAACGTCTGTGTTCTGTAGCGAACCTACACTACC
 GCAAACGCCCCAAAACAAGGACGATAAGTCTGTGAAGAAATGCAGTAACGTGAGGGAAAAACATACTG
 CAAACTACAGAGGTGTGGTACAAGAATTGAAGAGCCGCTAAACAAACGTATTGCCACAGCACA
 TACATACAACAAAGTCAATTCTACTCTCGCAACCGATTTCACCCACTGTCCCAAGCACT
 ACTCCAAACATTCTTCGCTAGGCCCTAAACCGACTAGAAGTGGCCGCCACCGACAAGAACTG
 CTCATTCCGAACATACACCGACAAACATCCAACAAACACAACAAAGTGGCATGAAAGCTATGCTATC
 CCTACAGCAAAGCATGAAAGACTTATGACGTTCATGCAAATACTTGCAAGAGCTCATGAAAACCAA
 AATATCCTGATTCAACTTCTGTATCTCAAATCCCATAATGGCTCCCTACGGATATCTGTGGAA
 CGCAAATGGCCTTCACGGCATAACACAAGAGCTCACACAGTTACGAAAAAACATCGACGTAATG
 M_A_F_H_G_I_H_K_S_S_H_S_S_F_T_K_K_T_S_T_*
 CTACTATCAGAACGACCTCACAAATAAAACATTTCATATACCAGGATACTTGTCTATGGTACAA
 M_V_Q
 ATCATCCAGATGGTAAAGCTCATGGAGGCAGCTGGAATACTCATCAGAAATCGCATAAAACACCACACTT
 I_I_Q_M_V_K_L_M_E_A_L_E_Y_S_S_E_I_A_*
 AAACAATTGACAAAAACTACTTACAATCTACGTCCATAGCCTTACAACATCAAACATGGTCAACGACT
 CTAGCCGAGTCTACTGCCACCGCGTTCCAATCTGTAGGGATCAATTGAAATTCTTAACACAC
 TAGGTGACAGGTTATCGCAGCGGGTACTATAACGCCAACACCCATTGGGGATCTGACTTGTGTC
 GCCAAAGGGTAAGCAATTGTACAATGCCCTACGAAGCCAGAAAACAAGCTAGACTATGTATCCCCGGGT
 M_R_L_R_S_Q_K_T_S_* M_Y_P_R_V
 AAGCCTACATACTGCCAGCAGACCAAGAAAAATCCCAGACCTGATCGATTGCAATTACTAAACATG
 S_L_H_T_G_Q_Q_T_Q_E_K_S_Q_T_* M_
 TCCCCCGCAACATGGTCACCGCCGAAGCACTAGCAGATTATCATCAGATCACTCACCTGTTTCTAAA
 S_P_A_T_W_S_P_P_K_H_*
 TATGCTAAGTGTCTGTTCACACATAGAACTAACGACGGCATTATCTACAAAGGAGGATATAGACAAGT
 CAACGGAAACTCTGAAAACATTAGTTGGCTGCAAAGGCTCAACCCGCCAGTGCAGTATGCAA
 M_Q_

ACCAAACTACATCAAAACTAATCGCAAATCGAGCGGCTGGTATTAGATAAACGACGCCTACGAAGGGAT
 N_Q_T_T_S_K_L_I_A_K_S_S_G_W_Y_*
 TGGCAGTCTAATAGATCACCAATTACTAAGCACATGCTTAAGATAGCCACACGCAGGCTTACCAATGCTC
 M_L
 TCAAACAAGAGGAAAAAACAGCCAACGTTCATATATCGAGCAACTCTCTCCCACCAGCACTAAGTACCC
 S_N_K_R_K_K_T_A_N_V_H_I_S_S_N_S_L_P_P_A_L_S_T
 TCTTTGGAGAGCTCACAGAAACCTAAAGACTCCAATAGCGCCAATTATGCCACTACGAAGTCCCTCTGGC
 L_F_G_E_L_T_E_T_*
 ACCTGGTTTCGAAGTGATGAAGAAAGAGCCAATGCTTCGCTGACCATTACAAAATGTATCCGACCAA
 M_K_K_E_P_M_L_S_L_T_I_Y_K_M_Y_S_D_Q
 ACCCCTCTACCAACACATTATTCTCCCTCTTAATAGCAGCCAATCTAGATCCTCAAGAACCTTGA
 T_P_L_P_T_H_L_F_S_L_L_*
 ATTCCGACCATGTGAACTAGCAAAGGTTATCAAAGAGCAACTGAACCCAAGAAAATCGCCTGGCTACGAC
 CTAATAACTCCAAGAATGCTCATTGAACTCCAAAGTGTGCTATTCTCACATCTGCCTGTTCAACCG
 CAATGCCAAGCTGGATACTCCCTCAAAAATGGAAAAGTCGACCATAGTAATGATTCCAAAGCCAGG
 M_E_K_V_D_H_S_N_D_S_K_A_R
 AAAAGATA
 _K_R_*

Para el gen 2R_58, el programa Augustus Gene Prediction predijo una estructura compuesta por 4 exones de 155 pares de bases el primero, 270 pares de bases el segundo, 236 pares de bases el tercero, y 226 pares de bases el cuarto, y 3 intrones, de 4998 pares de bases el primero, 1455 pares de bases el segundo, y 4461 pares de bases el tercero.

Se encontró acuerdo con espectros de masas para el péptido NPNWCSGVIPWDSMILTI con una probabilidad de $p=0.088$ y un valor $E=0.000421188502997275$; para el péptido VALQMTSLPYALLQF con una probabilidad de $p=0.015$ y un valor $E=8.00954401243523e-05$; para el péptido QEASEKPHSCK con una probabilidad de $p=0.082$ y un valor $E=0.000341167814746965$; para el péptido CLLNIREK con una probabilidad de $p=0.085$ y un valor $E=0.000236707608832088$; para el péptido ECAILNGFR con una probabilidad de $p=0.009$ y un valor $E=0.000872799071745708$; para el péptido FWITMECIALNGFRYTVK con una probabilidad de $p=0.022$ y un valor $E=9.13024638785673e-05$; para el péptido MVQIIMVVK con una probabilidad de $p=0.063$ y un valor $E=0.000842331872273208$; para el péptido FVLLNIENTAQPF con una probabilidad de $p=0.046$ y un valor $E=6.78997988356888e-05$; para el péptido MLALHLVWSSK con una probabilidad de $p=0.001$ y un valor $E=0.000686304066554346$; para el péptido SFSNFQKEGVAIFHNVVCSCSSYCGHHGTR con una probabilidad de $p=0.019$ y un valor $E=0.00048312585066518$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 42 sORFs. Se pueden observar repeticiones. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 10 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura,

pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_76



G __ *
CTGACCAACTTCAACGGAACCTAAGAACGGCTGCAGAGAACTACGACCTGATCGGCTCCTTATCATCC
AATTGACAATGAGACGATAATGGTCAACGGTCAAACACTATTCCAGTTACTCGGTAGTCATCTAATGGC
GATGCCGGCGTGGTGGCCACATAACGGCCAGCAACTTCAACTTCTCTGGAATACGTCCACGACGTG
AGCATGAAGAATTGGAAAAGATGTCCAACATGGCGAGTGAGCTACTAGCCTCTTCTCACCGAGGC
CACTCGCAATCTGCATATTCTAGGCTTTATTCTATGGAAGAAGCTGATGTCCACCAAAGGCATGCC
CGATGTCCGCGAGATTGCCGAAACTTAGAAGCATTGGGCCAAACCGAGCTGAACAAAGGCTCACTAATCT
GCGGGACGCGAGATCTGAGGGGGAGGGAGTTAAGAACCTCTTCTGCGCTCTCGTCAGGACTCACCAG
CGCTCGGCTCTCGTGTGTTGGGCCCCGTAGCAGGCGACTCGGGCCTGTCTAGGAACATGTTGTGA
M_F_V_Y
TGTGTGCATTCGGAACAAGTGCCGTTGGTCGCACTCAGGGTGGGGTCAACGGGGAAAGCGGATATAAA
V_C_I_R_N_K_C_R_W_S_H_S_G_*
M_C_A_F_G_T_S_A_V_G_R_T_Q_G_E_G_S_T_G_E_A_D_I_K
AGCAGCGGGCGGGAGAAGAGGCCAGTGTGAAACGACACATAACGGAACCGCTAGCAGATCGCGAAC
A_A_G_R_E_K_R_P_Q_C_R_T_D_T_*
TGAATCTTAAATAAGCTAACCGTAAACTCGAACCTCTTAACATCTGACTATTATTGGAGAACCA
CAGCATGTTGGTTGTATCGAGGTGAGGTATGCGCAGCGAGTGGCAGAACCTGATGCAAGTGGAA
M_R_Q_R_V_P_R_T_L_M_Q_V_E
CTTGCCTTAACCTATATGTATATAC
L_A_L_T_Y_M_Y_I_C_*

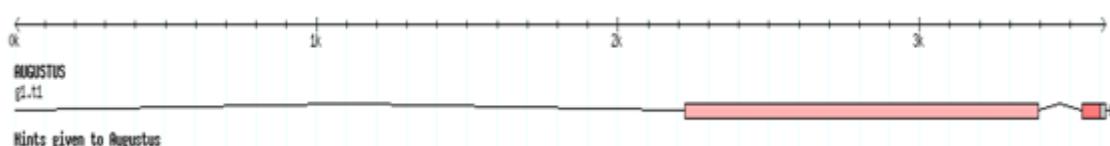
Para el gen 2R_76, el programa Augustus Gene Prediction predijo una estructura compuesta por 2 exones de 58 pares de bases el primero, y 948 pares de bases el segundo, y 1 intrón de 546 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido HNTTIQR con una probabilidad de $p=0.019$ y un valor $E=0.000167662151123091$; para el péptido NRPTSCVAVP con una probabilidad de $p=0.081$ y un valor $E=0.000320259711550587$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 14 sORFs. Se puede observar una repetición desplazada. Los sORFs decimosegundo y decimotercero son repeticiones desplazadas de los sORFs primero y segundo. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 2 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_86



GCATTCCCTTTAACATATAACAAAGTTAAATTGTTCCCTCGCAAATCCAACCACAAATAAGGCT
 TGAAAGCGAGATACGATTGGTATCCAGGAATATCTGACTTAAGCACATGCGACAAGTCTTCCTAC
 CCATGATTGCAACGCCTATAATATGCCACATCACGCCGTCTAAAACCGGAAAGCGTAACTACTACACGG
 M_I_A_T_P_I_I_C_H_I_T_P_S_*
 AGTTTAGTATTCAATGCCTCCAGCCCTCATCGAATGGTACCGAGCTTAAATGATATCCTCATGCTGGC
 M_P_P_A_L_H_R_M_V_P_A_* M_I_S_F_M_L_G_
 CTGTCTTACAGTCCGACTTGACCATTCAAATTCTGAAGCAACACGTGTGATGCCGGCACGGCAAGTAA
 L_S_Y_S_P_T_*
 ACAATTGTCGTGCTTTGACTCACGAAGCTGATGTCCTTGCAAAGCAGTTAACGATAACTGCTT
 CGTTAAATGTAGGCTGACCGGTGTCACACGACATTGGAGAAAACGGACATACACGGACAGGATGG
 M_
 TTTTCCTGTTGACAAGTCGAACTTTGATTTGGAGCCACTTCGTCTCATAGGAATTAGTTTC
 V_F_L_V_A_Q_V_A_T_F_R_F_W_S_H_F_R_L_I_G_I_*
 TAGAGGCCACTTGAGTTCACCGCTTGGAGTGCAGTGACTGGTACGGACTGTCACATCATCGAT
 GCCCTCTAGGGTTCGATGACGTTCTGTGAGGAAGGTGTTAGGTCTCCCCATGCGGGATGTCGGCTTC
 M_T_F_C_E_E_G_V_Q_V_S_P_C_R_D_V_G_F_
 M_S_G_C_R_L_S
 M_S_A_F_
 TTATGTAGCGACTGCGAGTTATTCGGAGCTGGATGAACACAGATATACCAGCAGGCAGTCCCAGTT
 L_M_*
 Y_V_A_T_A_S_Y_L_R_E_L_G_*
 L_C_S_D_C_E_L_S_S_G_A_W_M_N_T_D_I_P_A_G_S_P_S_
 CTCAGTGTGATGCCTGACATTCTAAGGCAGTCAAGCTACCTTGAAACAGTACTTGCAGTACCTCAAG
 S_Q_C_* M_P_D_I_S_K_A_V_K_L_P_*
 GCGCCCCAGATTCTGTGGTATCGACTGCACATTAAACAGTATTTCATTGACTGTTACCAACAATC
 GTTATTTCGAAACGCTCTATTAGGTTTCACACGAGCGGAAACCTCGTTGGTGGAGAGGCGAAAT
 CGAAACTATGGCATGCACGTCGCCACTTGTGTTGGCATTAAATGGAATAACTATTCAACTGGAGTTAGC
 M_A_C_T_S_P_L_V_L_A_F_K_W_N_N_Y_S_T_G_V_S_
 M_H_V_A_T_C_F_G_I_*
 CGTGGATTATTGATATAATGGCTGTGAAAGATCCGGAAAGTCGGCCAGCGAAGATAGTCGCCTGCGA
 R_G_L_L_I_* M_A_V_K_R_S_R_K_V_G_Q_R_R_*
 AAACTTCTGTATCGCATGGAGGCAACCGACAGCCAGAGGAATGTAGGCTGGCGCAGCGTTCGCGC
 M_E_A_T_D_S_Q_R_K_C_R_L_G_A_Q_R_S_R
 TGGGATGGACTGAGACGTGCCCTGCTCGATTTCACAGCAGCTGGCAACACACCTTCATAGACTGAA
 L_G_W_T_E_T_C_P_A_R_F_Y_Q_R_A_G_Q_H_T_F_H_R_L_N
 TAGCAATAACTGTATTAGCCCTGAGAATAGGCATGTTGCCTGCGCTTCGCGCTGACACAAGGC
 S_N_N_C_I_*
 ACTCTGAGCAGAGGTCGAATTCTTTCAACCTTGTCCATAGGGTCGGACTTGGTCGCGACGGACGCT
 AATCATCGTGACGGTTGGAGCTCGGATTCCGGAGTGTGATCTGAGCCTAAATCGCTTAAGCGGGCA
 GAAACGAAATGAATTGGCTAGCGCTAGATCGGAAGCAGCCATATTTCGCTGCGCTGTACTGTGG
 M_N_L_A_S_A_R_S_E_A_A_I_F_F_A_V_R_C_T_V
 CTTGGATGGAGTAGCACAGTCGTCGAAATCTGCGCAGGGCTTTCACCGACATGCTTGAGATTCTGG
 A_L_D_G_V_A_Q_S_S_E_I_C_A_G_V_F_T_D_M_L_E_I_L_G
 GCCCTGTGGTAAAAAATAGACCTGCGTTGTGCGGACAATTCTTATCGTCCCCGATGGCAT
 P_L_W_* M_G_I
 ATCGAAGAAATACGAAATGAAAGGAAGCGGTTGGAGCCGGTCACACGTTGAAAAGTAGACAGA
 I_E_E_I_R_N_E_R_E_A_V_L_E_P_G_H_T_F_E_K_V_D_R
 M_K_G_K_R_F_W_S_P_V_T_R_L_K_K_*
 TTCCTCAGAATGCACTTAATAAATTAGCTGCGCCGTGAACGGTATAAGCAGCGGAAAAGACCGT
 F_L_R_M_H_L_I_N_L_S_L_P_P_*
 ATAGGATGTAATGGGTGAGAAGGTGGTAAATTACGAAGTGGAAACGCCGTAGTTAGACTAATTGG
 ACAGGTGACTCGGAGTGAACAGCAATTATATAAAATAATATAAAATAATAAAAAAATTTCAA
 AAAAATAATTAAATAATTGAAAAAGTTAGGAAACCGTAAACGGGAAATTGATGGAAAACACGCC
 ATTGCTCGGAAATTAGGGAAATTACGGAAAATTGATGGAAAACACGCC
 M_E_N_K_T_P_F_P_R_R
 CACTTGGAAATAATTATTGTGGTTGGATTCCGCCACACGTTGTCACCGAAACACCTCTTT
 H_L_E_*
 CCAGCAATTCAAGCCCTCAAATCCTGCAAGGCCAATTCCGCTAATCAGGCCAATTGCTTCAAATGA
 M_
 GCAAGCCGGTGTCAAATTAAACCACGGGCTCAAGAGCTATCCTCTGGACTGCCATAATCAAT
 S_K_P_V_F_K_I_I_*

ATTTCCCATCTTGGCACTAACTTAAGGCACGCGCCCTGATCGACTCCGGATCAGAGGCACATTATAA
 CCGAGCGACTGTTCAATCTAAATTAGATTGCCATTCCAGGTGGTCAAGTCCAGGTCTCGGGCTTAAACCA
 AACAGTAGCTGCTCAGTCCAAGAAGCTCTGCAGTTACCATCCGATCTCCGACTAGGCCCGCGTGCAG
 TTGGAGACGACGGCCTATGTCCCTCAACTAGCCGAAATCTGCCTTCCTACCCAATTCCGAAAATT
 TCCTTCGGGATCTCCGATTTCACGGCGATCCAAAATTCTATGAGAGCGCACAAATAGATGTACT
 M Y
 TATCGGAGCCGACATCCTGCCCTCGGTGCTTCTGAGTGGAGCAAAACCAACATCTGTGGCTCTCTTGT
 L S E P T S C L R C F *
 GGGCAAGAGACCATTTCGGCTGGGTACTAAGTGGCCAGTGTCAAGCCTCAGCCCAAAGCAAATTCCCT
 CTTTTGACACAGATCTCCACCGTGACGATAATTCACTGGACAAACTCCTCACAAAATTGGGAGGT
 GGAGGATATACCAACAAAGTTGGTAAAAGAATCCGATTCCATGTGCGAGAAGAATTCCCTCAAACGACC
 ACGAGAAACGAGTGCAGCAAAATATGTCGTTACTCTGCCTTTGCGACCCGAACATATCGTTCCGGGC
 M S L L C L F A T P N I S V P G
 TAGGGCATTCTAGGTCTTCGCGTTGGCTCAGTTAAAGAAATGAGCAGCGTCTAAAAGAGATGAGGC
 *
 CTTGAAAGCGAGATACGATTGGTGTCCAGGAATATCTGACTAAAGCACATGCGACAAGTTCCCT
 ACGCATGATTGCAACGCCTATTATATGCCACATCACGCCGTCTAAAACCGGAGAGCGTAACACTAAC
 M I A T P I I C H I T P S *
 TCCGTGTAGTATTCAATGCCCTCCAGCCCCATCATCGAATGGTACCGAGTTAAATGATATCCTCATGC
 M P P A H H H R M V P V * M I S F M
 TGGCCCTGTCTTACAGTCCGACTTGACCATTCAAATTCTGAAGTGGCGCTATTCCGATACGTGTTCAAC
 L A L S Y S P T *
 GCCGATATCGAGAAAATGTATCGGCAGATCTGGTAGGTCCGAAACACACTCCATTCCAGCGAATAC
 TCCGTAACAATAGAGGGAAATCAGAGATTGAAACAGTAACCTTGGAGTCAGCTAGCA
 ATGTCATTGAAATTTCATGTATGTGGATGATGTTAGCCGGAGCGGACTCCACCGAAGAAGCGAAGCT
 M S F E I S C M W M M F *
 M Y V D D V L A G A D S T E E K L M V Q E R
 CATGGTGCAAGAGCTCGAGACGCTCTGAATTCCGCCGGATTCCA
 M V Q E L R D A L N S A G F P *

Para la región genómica 2R_86, el programa Augustus Gene Prediction predijo una estructura compuesta por 2 exones de 1172 pares de bases el primero, y 76 pares de bases el segundo, y 1 intrón de 147 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido MGIIIEIR con una probabilidad de $p=0.084$ y un valor $E=2.97470105064206e-07$; para el péptido YVDDVLAGADSTEEAKLMVQELR con una probabilidad de $p=0.093$ y un valor $E=5.81298966985286e-05$; para el péptido MYVDDVLAGADSTEEAK con una probabilidad de $p=0.023$ y un valor $E=7.71602349819706e-05$; para el péptido TFCEEGVQVSPCR con una probabilidad de $p=0.068$ y un valor $E=2.88417332453133e-05$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 23 sORFs. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 4 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_88



_R H K E T I D G T A H P T T K R C S G A R *
 ACCCTGGTCGAGATGGCAAGGACTATGATGATTACGCAGCGTCGGCCACTCACTATGGGCTGAAGCTA
 TCAATACTGCTGCTTATCTACGCAATCGCCTGAGACGTACGCATTATCTGATGTAACACCCTCGAGTC
 TTGGACTGGAAGGAAGCCATATGTGTCACCTGAAGATATTGGTCAAGGCTATCGTCTAACAG
 TCCACAAAAAGGAAGTTCTCGAAGGGCAAGAAAATATTGGTGGATACTCTGATGCTTCAAGG
 M L L R
 GATATGCCCTGTTCAATCCTATCAGGAAGAAATATCTGTTGCTCGTGACGTAATTGATTTGAGAACGA
 D I A C S I L S G R I S V L L V T *
 CCAGGATGATGGTATGACGGCAGGGCAAGCAGTACCTCTCCGATGTTCAACTTGAGATGCAGCAC
 M F N L W R C S T
 CTTCCAGTCTGTGTTGCTGAGGGTAAGGCAAGAGTACGGATGAGGTTCCAACCTCAAGAAGCGTCAAGGA
 F Q S V L L R V R Q E Y G *
 GCGGAAACCATAAGGAACCTGAAGAATGGAGAACCTCAATGCAGAAGGAGTTGGAGAGCCTACGTGCA
 M E N L N A E G V G E P T C
 M Q K E L E S L R A
 AACAAAACCTGGTCATTGGGGATTGCCGGCAGGTGAGAAGGCCATTGGTCGAAAGCGTGAAGCGTAA
 K Q N L V I G G F A G R *
 N K T W S L V D L P A G E K A I G S K A *
 CAAGATGGCAAAGTCGAGAGGTTAACGACTCGACTTGCCAAAGGGTGCCTACGCGATAACGGCGTT
 AACTTCACGGATACTTCTACCAAGTGGCACGCTACTCATCAATTAAATTAGTAATTGCTTGGCGGTGG
 AAAACGGCTCTACATGCACCAAATGGACGTCTCGCATACTTGAATGGTACACGAAACGGT
 M V I F T K R
 ATATATGAGGCAGCCAGAGGATTCATCGATGAACGATATCAAAGAAGGTGCTGAAGTTACACAAATCT
 Y I *
 ATATATGGACTGAAGCAGAGCGGCCAGAATGAAATAACTACTGAACGAAGTACTGCAAAAGATTGGGT
 TTTCTTCATGCCCTAGCGAGCCATGTTACACCGTAATTCTGGCAATAGTAAGAACCTTGTGTAAT
 GTACGTAGACGACCTTATCATAGCCAGTCAGCAAGGAGGAACGTGCGATATTAAAGCATCAATTCA
 AAAGAATTGATGCGTAGACGGGGCAGCTAACGACATTCTGGTATCGAAATTGAACGTGACGGAG
 AACTGGTGAATCAGGATTGCCACAAGCAGTATATTGAGAGCCTTATCAATGATTATCGATGCAGGA
 M I I R C R
 TTGTAAGCCGAATCTCATCCCACGGACTGGAGCAGGCTTGAAGTAAAATGTGACAAGGCCATTGTCAGAAG
 I V S R I S S H W K Q A L K *
 GTGAATCAAGTCAGCTTCAATCGCTGATTGGCTATTAATGTTCTGGCAATCACAACCTCGCCTGATA
 TTATGCATTGGTCAATTAAACTATCACACGGAACTCTGACCCACATAAAGAGTACGAAGCCGGTCAAA
 CGAGTTCTGCAGTACTTGAGGGGACAGCTGATTGAGCTACACTACGAGCGTACTGGTGTGCCTATA
 CAGTGCTATGTTGACGGGATAGGGCTGGTACACCACGGACCGAAAATTCTTACTGGATGGCATGTA
 M L T R I G L V T P R T E N S L L D G H V
 TTGCTGCAGGAGCTGTTTACGTGGACTCAAAGAACATCAGTGGTTCCCTAACGAGCACAGAGTC
 L L Q E L L R G T Q R N N Q W F P *
 AGAGTATGTGGACTTCCATGGCAGCGAAGGATGTGGCTATGTTGGAAATTGGTCAACGAAATGGGT
 M W H F P W Q R R M W R M F G N W S T K W V
 TTTGGTGAACACAGGCAACTAAGGTTATAGCGACAACCAGAGTCCCTGGTCTAGTGAAGAAATGAAA
 L V K H R Q L R F I A T T R V P S A *
 CTTTCCATGCACGTAGTAAGCATAAAATATCATTATATAAGAGAACTGTATAAGAACAAATATAAGAAG
 TTAATTATGTACCCACAGAAAACATGATGGCAGATGTTCTAACCAAGAATTGAATAGATTAAACATGA
 M
 AAAGTGTATCCAAGGGATGGGTTAAACTAACAAAAATGTATTGATTTGAAATTAGATAGAAATAT
 K S V S K G W V * M Y F D F G I K I E I
 TATCGTAAGGGTCGACATATTGCATTGAGAGGGAGTGTGAAAATATGTATGTAATATGTATGATATA
 L S V R V D I L H * M Y V Y
 TAATAATATGTAATAAAAGTCATGCAGTGTCTCCCTTTGGTCGGTAACCAAAGCTTTCT
 I I I C N K V N A L C L P L L V A V T K S F F L
 M H C V S L F W S R *
 CTTATTGTGTTATCCTCTTACGTGTAATTGGCTGCCTCGTGCAGTAACATTGACTCTAGATCAGT
 L L C Y P L *
 CACAATAAAACTTGAAACGAATGGGGTTATGGGCCAGCCCACGCGGACATAAAAGTAATAGTTCTA
 M G V M G P A H A D I K V N S S
 AACGAATTAGAATATTGGCATCTTAAATATTGTGATTGAGGGATTAAACGAAAATCGAAGT
 K R I R I F G I F K Y C D S G I *
 GGAAATGAGTCATCAATAACCAAATAGAAAAACTTGATGATGAAACTACAGTGCCTGGCTGTACAA
 M M K T T V R G L Y K

ATGAAGAGTGTCTTAATTGAGAATTATGGGGGTGGTGTGGACGTGTGGTTAAAACGAAAGTG
 — * M_Q_N_Y_G_G_W_C_V_D_V_W_L_K_T_K_V_
 M_G_G_V_W_T_C_G_*
 ATAGTGCAGCTAAAGGCTTGTGACCGAAGGACGAAAAAGCATTAGCAAGTATAATGCTATGCAT
 I_V_L_S_*
 TAAGACATCCCAAATTAACCATAAAAAACTGTGAGACTGCTGTAGAGGCATGCCAAAGACTTAGTGAA
 ATCCACACTCCCTCAGGACCGGCACGACGTATATGTTGCTAAAGCAGTTGTCACATGAGAAATGTCTG
 M_F_A_K_A_V_V_A_H_E_N_V_*
 AAACAGAAGTTGTTGAGTCATGTGAAACAATTGGTGCAGCTGTTGAAAAACTAAAGAAATTCAATT
 GGTGATCCAAGAAGAAGTCCTGAGTATTCTCCTGTTGTCAGTTGCCAACATTGAAAATGTTAAAATAAAATTACAAGAGGAAGGGC
 AAAGCGTATGGCAAATTAAGAACATTGCAAAAAGCGAACAAAGTGCATTGGAATTGGTCTGCGAA
 ACAAAAAGCGAAAATGACATTAAGAAGAGTGTGCAAGTAAATAATCAGCAACTGATTAACGGAAAAGA
 ACAGTTAATTGTTGAACTGTGGTGCAGCGGCCACAAAGCTGTGCTCAACTGTACAGCTTGGCG
 ATTGCCAAAAAATATGTTGCTGCTGATTGAGCAACGGCTCATTGTCAGGAGATCGATGTT
 TAAAAGCTTCAGAGAGCATAAAGAGCGCATTGTTGGCAATAAGTATATTATGGCTGACGGTCGT
 GGTACAGTAAAATAGCCTGGCGCAACTCATCATTGAAATTGATCGACGTACTCTTGTAAAGAATTAC
 AATGCAACTTATGTCGGTGTGCAAGGCAATTGAAAACGGATTGTCGTTGCTGAAACAGGCG
 M_Q_L_Y_V_G_V_E_G_N_*
 AATTTAAAAAAATGATAAGAATAAAAGTTGTTGATTGCTGAACTGCAAAGTGATTGTTATGTTCAA
 AATGAAAGAAAATGAAAGTGCATGTTGTCACAGACAAATTAAATGAGAAAGTGGCACCAAGAGAT
 M_K_E_K_L_K_V_H_V_S_L_H_R_Q_I_*
 M_F_R_C_T_D_K_F_N_E_K_V_A_P_E_I
 TCGGTCAATTGAACTTGCAAGCTGAAACAAATGATCAAACAAAGAAATGGTACTCGGACTAAAGAAAAA
 R_S_F_E_L_C_K_L_E_Q_N_D_Q_T_R_N_G_T_R_T_K_E_K
 ATATTAAAGTGGCGCAAATAAAATGACTGTTGAGCTGCGCAAAAGCAAGATATGTTGAAAGAGTTTC
 I_F_K_W_R_K_I_K_* M_C_E_E_F_
 CAAAAGCCTCTGAAATCGCACAAATTGATGTTGAGCTAGTGCATAGTGAATTCTGTGGTCAAATGC
 P_K_S_L_W_K_S_H_N_*
 AACGACGTCTGTTGGAGGTGCACGCTATTGCACTTCGTAGATGACAAATCGAGATACTGTTGT
 M_T_N_R_D_T_C_L_
 GTATTTATAAAGACGAGAGATGAAATACTGACCAATTCAAGGAGTTAAAGCATTGCGAAACCAA
 C_I_S_*
 AGAAGTTGAAAGCAATAAGGAGCGAACACGGCGTGAGTATTAAAGTAAAGCCTTCAATGTATCTGAC
 M_Y_L_D_
 AGAAAACGGCATAAAAGAGACAATTGATGGTACCGCACACCCCCACAACAAACGGGTGAGCGGAGCGC
 R_K_R_H_K_E_T_I_D_G_T_A_H_P_T_T_K_R_C_S_G_A_R
 AACCGAACCTGGTCAGATGGCAAGGACTATGATGATTGACCGCAGGGCGTGGCCACTCACTATGGGCTG
 *
 AAGCTATCAATACTGCTGTTATCTACGCAATCGCGTGAGACGTAGCATTATCTGATGTAACACCGTT
 CGAGTCTGGACTGGAAGGAAGCCATATGTTGCTCCACCTGAAGATATTGTTGCAAGGCTATCGTCTT
 ACAAGTCCACAAAAGGAAGTTTCTGCAAGGGCAAGAAAATATTGTTGGACTCTGATGCTT
 M_L_
 CTAAGGGATATCGCCTGTTCAATCCTATCAGGAAGAATATCTGTTGCTCGTGACGTAATTGTTGA
 L_R_D_I_A_C_S_I_L_S_G_R_I_S_V_L_L_V_T_*
 GAACGACCAGGATGATGGTATGACGGCAGGGCAAGCAGTACCTTCTCCCGATGTTCAACTTGTGGAGATG
 M_F_N_L_W_R_C
 CAGCACCTTCCAGTCTGTTGCTGAGGGTAAGGCAAGAGTACGGATGAGGTTCCAACCTCAAGAAGCGT
 S_T_F_Q_S_V_L_L_R_V_R_Q_E_Y_G_*
 CAAGGAGGCGGAAACATAAGGAACCTGAAAGAATGGAGAACCTCAATGCAAGAAGGAGTTGGAGAGCCTA
 M_E_N_L_N_A_E_G_V_G_E_P_
 M_Q_K_E_L_E_S_L_
 CGTGCAAACAAAACCTGGTCATTGGTGGATTGCGGCAGGTGAGAAGGCCATTGGTCGAAAGCGTGAA
 T_C_K_Q_N_L_V_I_G_G_F_A_G_R_*
 R_A_N_K_T_W_S_L_V_D_L_P_A_G_E_K_A_I_G_S_K_A_*
 GCGTAACAAGATGGCAAAGTCGAGAGGTTAAGTCTCGACTTGTCCAAAAGGGTGCCTCAGCGATAC
 GGCCTTAACCTCACGGATACGTTCTCACCAGTGGCACGCTACTCATCAATTAAATTAGTAATTGTTGG
 CGGTGGAAAACGGTCTCTACATGCACCAAATGGACGTCTCGTCATCAACTTGAATTGATCTCACGA
 M_V_I_F_T_
 AACGGTATATATGAGGCAGCCAGAGGGATTGATGAAAGATATCAAAGAAGGGCTGAAGTTACAC
 K_R_Y_I_*

AAATCTATATGGACTGAAGCAGAGCGGCCGAGAATGGAATAAACTACTGAACGAAGTACTGCAAAAGA
 TTGGGTTTCTTCATGCCCTAGCGAGCCATGTGTTACACCGTAATTCTGGCAATAGTAAGAACCTTGT
 TGTAATGTACGTAGACGACCTTATCATAGCCAGTTCAAGCAAGGAGGAAGTGTGCGATATTAAAGCATCA
 ATTCAAAAGAATTGATGTCGTAGACGGGGCGAGCTAACAGACATTCTGGGTATCGAAATTGAAACGTG
 ACGGAGAAACTGGTCCAATCAGGATTGCCACAAGCAGTATATTGAGAGCCTTATCAATGATTATCGAT
 M_I_I_R
 GCAGGATTGTAAGCCGAATCTCATCCCACTGGAAGCAGGCTTGAAGTAAAATGTGACAAGGCCGATTGT
 C_R_I_V_S_R_I_S_S_H_W_K_Q_A_L_K_*
 CAGAAGGTGAATCAAGTCAGCTTCAATCGCTGATTGGCTCATTAATGTATCTGGCAATCACAACTCGTC
 CTGATATTATGCATTGGTCATTAACATCACAACGGAACTCTGACCCACATAAAGAGTACGAAGCCGG
 TGCAAAGCGAGTTCTGCATACTTGAGGGGACAGCTGATTGCAGTTACACTACGAGCGTACTGGTGTG
 CCTATACAGTGCTATGTTGACGCCGATAGGCTGGTACACCGAACGGAAAATTCTTACTGGATGG
 M_L_T_R_I_G_L_V_T_P_R_T_E_N_S_L_L_D_G
 CATGTATTGCTGCAGGAGCTGCTTTACGTGGGACTCAAAGAAACAATCAGTGGTTCCCTAACGAGCAC
 H_V_L_L_Q_E_L_L_R_G_T_Q_R_N_N_Q_W_F_P_*
 AGAGTCAGAGTATGTCAGTGGCACTTCCATGGCAGCGAACGGATGTGGCGTATGTTGGAAATTGGTCAACGAA
 M_W_H_F_P_W_Q_R_R_M_W_R_M_F_G_N_W_S_T_K
 ATGGGTTTGGTCAAACACAGGCAACTAAGGTTATAGCGACAACCAGAGTCCCAGTGCCTAGTGA
 W_V_L_V_K_H_R_Q_L_R_F_I_A_T_T_R_V_P_S_A_*
 ATGAAACTTCCATGCACGTAGTAAGCATAAAATCATTATATAAGAGAAACTGTATAAGAACAAATATAA
 TAGAAGTTAATTATGTACCCACAGAAAACATGATGGCAGATGTTCTAACCAAGAATTGAATAGATTAA
 AC

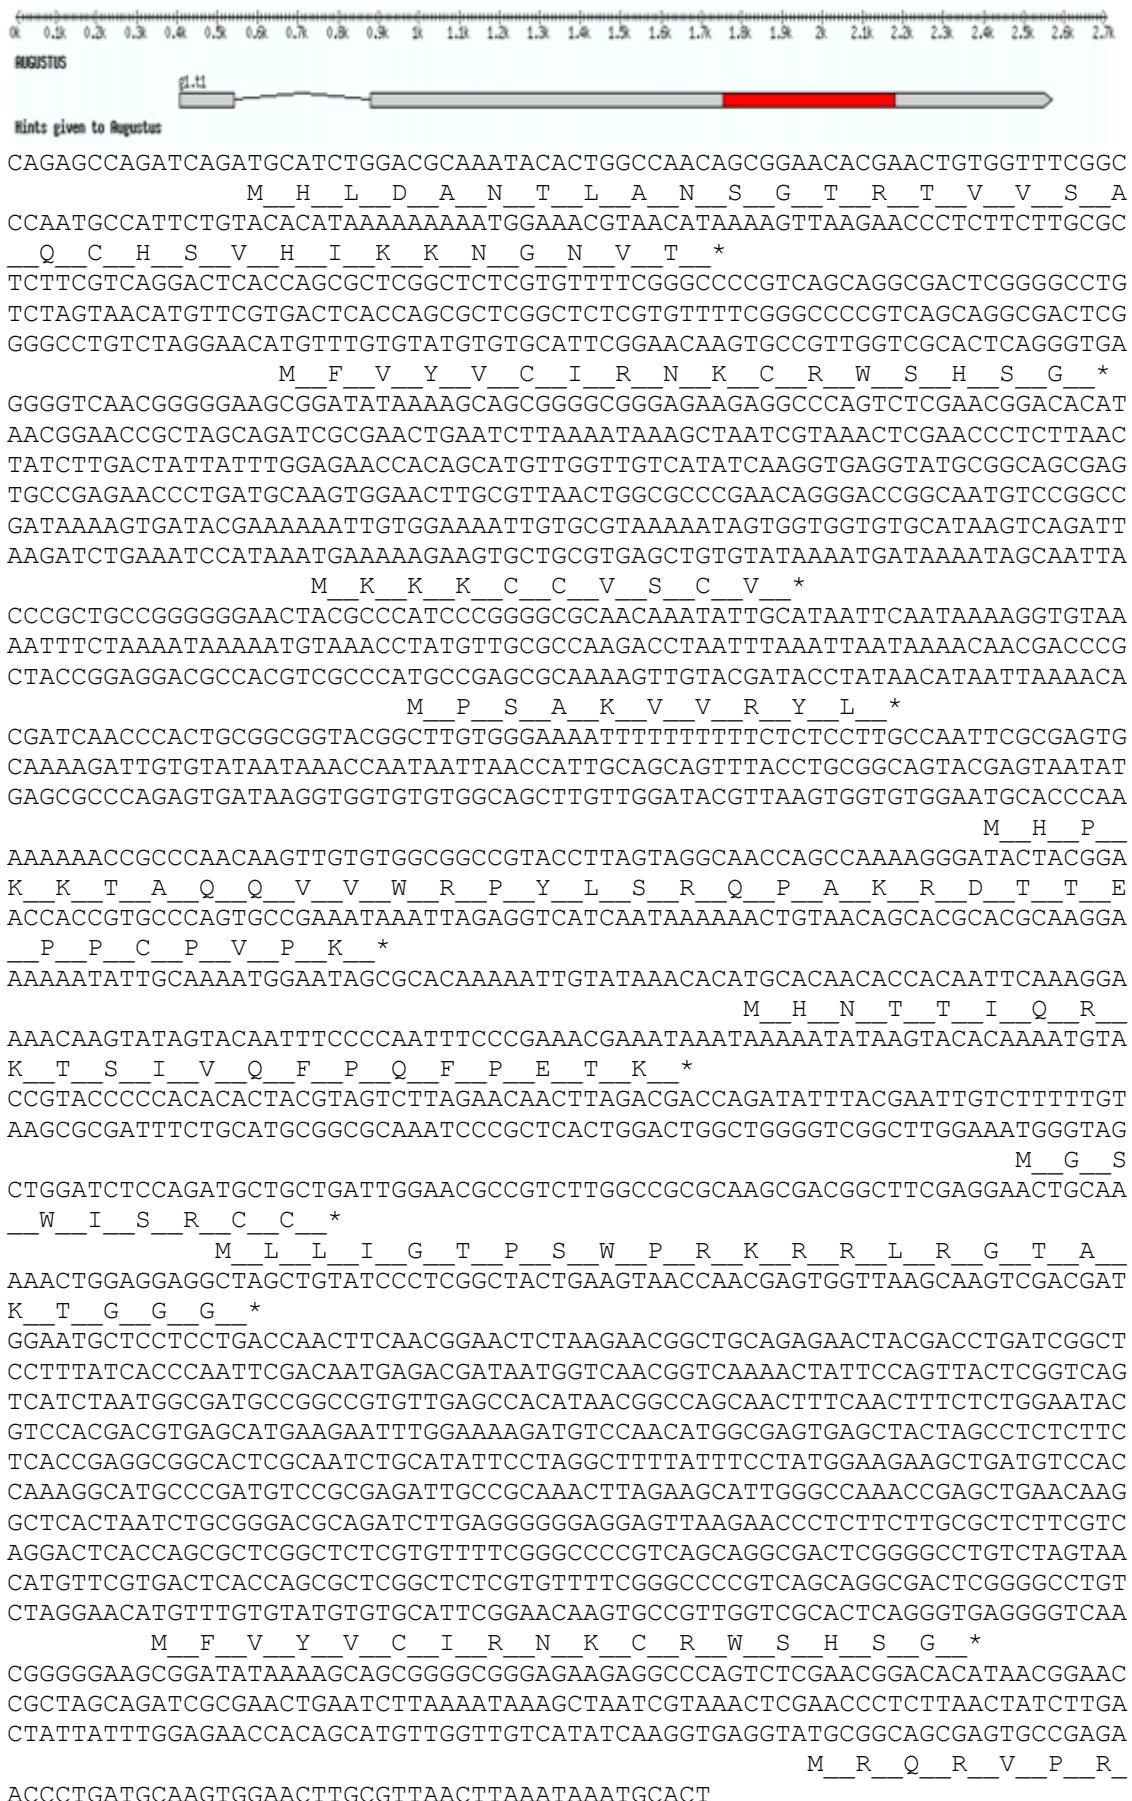
Para el gen 2R_88, el programa Augustus Gene Prediction predijo una estructura compuesta por 3 exones de 1377 pares de bases el primero, 136 pares de bases el segundo, y 604 pares de bases el tercero, y 2 intrones de 2689 pares de bases el primero, y 284 pares de bases el segundo.

Se encontró acuerdo con espectros de masas para el péptido ENLNAEGVGEPTCK con una probabilidad de $p=0.092$ y un valor $E=7.73884335297232e-05$; para el péptido FNEKVAPEIR con una probabilidad de $p=0.052$ y un valor $E=5.56497689739542e-05$; para el péptido ELESLRANK con una probabilidad de $p=0.044$ y un valor $E=0.000188347883869834$; para el péptido YVYIICNK con una probabilidad de $p=0.005$ y un valor $E=9.64541922302759e-05$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 45 sORFs. Se pueden observar repeticiones. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 4 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_89



_T_L_M_Q_V_E_L_A_L_T_*

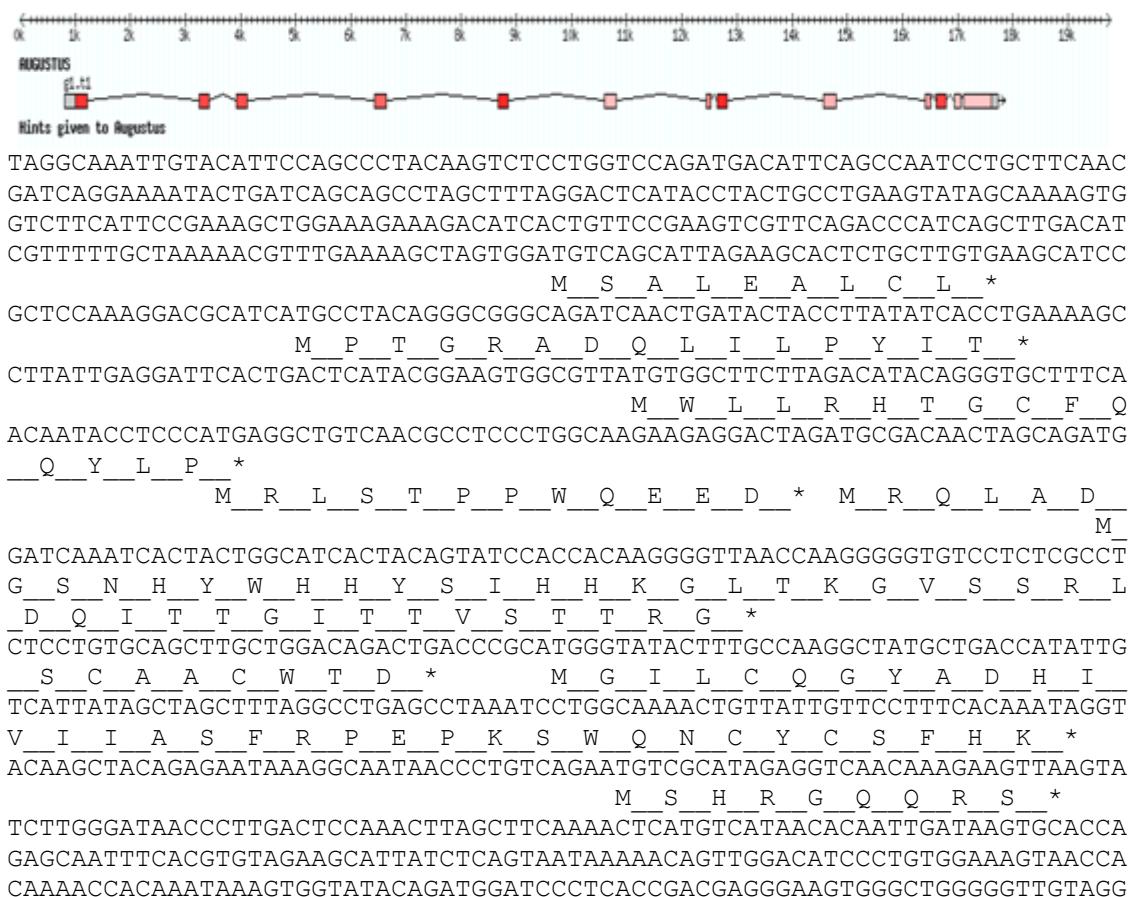
Para el gen 2R_88, el programa Augustus Gene Prediction predijo una estructura compuesta por 2 exones de 134 pares de bases el primero, y 1688 pares de bases el segundo, y 1 intrón de 340 pares de bases.

Se encontró acuerdo con espectros de masas para el péptido HNTTIQR con una probabilidad de $p=0.019$ y un valor $E=0.000167662151123091$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 10 sORFs. Se puede observar una repetición. El noveno sORF es una duplicación desplazada del segundo sORF. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de un péptido definido por espectrometría de masas que cumpliría con los requisitos mínimos establecidos en este trabajo ($E < 0.001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

Gen 2R_96



M_D_P_S_P_T_R_E_V_G_W_G_L_*
 CCCCCATGTTGAAATACCAACGAATCAATGGGCAGATACACCAGCATTTCAGCTGAAGCCTATGCTATT
 M_L_L
 GGACGCTGTGCAGAGTTAATCTGCAAAGGAACTATCGTGACAAGGACATTGATATACTGTCTGATAGTC
 D_A_V_Q_S_L_I_C_K_G_T_I_V_T_R_T_L_I_Y_C_L_I_V
 AAGCAGCCATAAAGGCAGCTCAGCAAAGCTAACATAAGCTAACATCTAAGCTAGTAAATGAAGTGAGAACAGCCCC
 K_Q_P_*
 AGACAAACTAGGAGCTGTCAACAAACTCACAATAAGGTGGTCCCAGGACACAACACATCCGGAAAT
 GAGCTAGCGAACACCTAGCCAGGAAGGGGCCAGAGAACCCCTCAATTGGGCCAACATTCTGTGGTGT
 TGGTCACCACAGAGTACTGGGCTACTTAAGTCATAGCGGAAGAAAACGCTCTGCTTCTGGAACAC
 CTACCAAGGACTTAGGCAGTCTAACGATTCTCCGTGAATATAACCATAAAAGGTTCAAGACCTTAATGA
 CATACGGGAAAACACCGTGCGCATTTGACTGGCCTCTTACGGGCATTGCCGACTTCACAGCATT
 GCACAAGATTGGCATTGAAGACTCTGTCACGGAGGAGAGCTCACGACATATTATATGTGACTGC
 ATGGCCTCAATCAAGAGAACAGATTCCCTGGCATGTATGTAGTCCCACGGGAAACAATTACCCAAT
 M_Y_V_V_P_R_E_T_I_T_P_I
 AAAATTCTGGCATTTACAGTCATTGGACTTCAGGGGATCTTGAGTCATGAAGGGTAGTACAATA
 K_F_W_H_L_Y_S_A_L_D_F_R_G_I_F_E_S_*
 GATCTGACTGGGTGCGAGTACACAGACAAATCACTAACATAATAACTTCATAAGTCAAGCTAACAGAGGC
 CTGCTCACAAAGTTTAGAACAGTAATGGCTTTAATGGACCAACACGAGATTGAGCAATA
 M_V_F_N_G_P_T_R_D_F_E_Q_Y
 M_D_Q_H_E_I_S_S_N
 TAACTAGCCGGAACGCTTCCTCCTGGACACAATGTAACACAGCACCATAAGCCTAAGGCTAGCA
 N_*
 I_T_S_R_N_A_F_L_L_W_T_Q_C_K_H_K_H_H_K_P_*
 TCGCTAAACCCATGAATTACACGATCTGAACTGAGTCCAGCACAAACGTTGGAAATTGCTAAAGC
 TAATACAAAGCTAACATATCGAGCCATTGCTATTGAGACTCGGGTATGCTTAAATGCCAGGATAACTT
 CCTCCTACAGAGCTGTTGAGAACAGATTTCACCTTGCGATGACGTGCTCAAAGTCAAATCGTAAACC
 M_T_C_P_K_S_N_R_K_T
 TCGCAAGTGAGGATGCCTACCGAATAACTGACCATGTATGAGTTAGATCAGGAGATCAGGAAATCCA
 S_Q_V_R_M_P_T_G_I_N_* M_Y_E_F_R_S_G_D_Q_E_I_Q
 M_S_L_D_Q_E_I_R_K_S
 AACGAAGGAATTATATAACCTCTGGAGGCAATAGTAAACACATGTGAAGGCCTAGACTTCACTGAGC
 T_K_E_L_Y_N_L_L_G_G_N_S_K_H_M_*
 K_R_R_N_Y_I_T_F_W_E_A_I_V_N_T_C_E_G_A_R_L_H_*
 AATCTCCAAGGAGTACAGAACATCAAATCAGGCACTATGAAAGGAGGATAACTCTTAACTATAGGAAGT
 AAGGAGAAACTTGAGCTACTACTGGCAACTCACTTCCGGAAAGCACGCTCAAACGGATGGAAATACCC
 CGGTAACTGCACAAAGTAGACCAGCTGACTGATTGGCCAAAGCAAATCACAAGTAACACAGAGAG
 ATTAGGATAGGCAAATTGTACATTCCAGCCCTACAAGTCTCTGGTAGATGACATTGAGCAATCCTG
 M_T_F_S_Q_S_C
 CTTCAACGATCAGGAAAATCTGATCAGCAGCCTAGCTTAGGACTCATACCTACTGCCTGGAGTATAGC
 F_N_D_Q_E_N_T_D_Q_Q_P_S_F_R_T_H_T_Y_C_L_E_Y_S
 AAAAGTGGTCTTCATTCCGAAAGCTGGAAAGAACATGACTGATCCGAAGTCGTTAGACCCATCAGC
 K_S_G_L_H_S_E_S_W_K_E_R_H_D_*
 M_T_D_P_K_S_F_R_P_I_S
 TTGATATGTTTGCTAAACCTGGAAAAGCTAGTGGATGTTAGCATTAGAACGACTCTGCTTGGA
 L_I_S_F_L_L_K_P_W_K_S_* M_L_A_L_E_A_L_C_L_W
 GCATCCGCTCCAAGGAGCAGCATGCCTACAGGGCGGGCAGATCAACTGATACTACCCCTATATCACCTG
 S_I_R_S_K_G_R_S_M_P_T_G_R_A_D_Q_L_I_L_P_Y_I_T_*
 AAAAGCCTATTGAGGATTCAATGACTCATAGGAAGTGCAGTTATGCTCTTACAGACATACAGGGTG
 M_T_H_K_E_V_T_L_C_A_F_L_D_I_Q_G
 M_C_L_L_R_H_T_G_C
 CTTTCGACAATACCTCCATGAGGCTGTCAACGCATCCCTGGCAAGAAGAGGACTAGATGCGACAAACCAG
 A_F_D_N_T_S_H_E_A_V_N_A_S_L_A_R_R_G_L_D_A_T_T_S
 F_R_Q_Y_L_P_*
 M_R_L_S_T_H_P_W_Q_E_E_D_* M_R_Q_P
 CAGATGGATTAAATCACTACTGGCATGACCACTGTAGGAGGACAGTCGTCACGGTACTTGCTGGTCTAC
 R_W_I_K_S_L_L_A_*
 A_D_G_L_N_H_Y_W_H_D_H_C_R_R_T_V_V_H_G_T_C_W_S_T
 TTGCTGGTAGACGAGTTGCTGGACAGACTGACAGGGCAGGGTCAATTACAGCTGGAGGTAAATATGAGGAA
 C_W_*

ACACCTCTGCGATATCATTCAACTGGGCCTCGAGTGGTGCAAGGAAGTAGGCCTGAGAGTAAATCCTAGCA
 AATCTGTTATTGTTCTTCACGAATAGGTACAAGCTACAGAGAATGAAGGCAATAACCCTGTCAGAATG
 M
 TCGCATAGAGGCCAGCAAAGAAATTAAGTATCTTGGATAACCCTTAACCTCAAACCTAGCTTCAGAAACT
 S H R G Q Q R N *
 CATGTCGATAACACAATTGATAATGCACAGAGCACTTTCACGTGAGAAAATTGCTGGTGGTAAGT
 M S I T Q L I N A P E H F S R A E K L L V V S
 M H Q S T F H V Q K N C W W *
 CGTGGGAACCTCACTAAAGATGGCTGTACCTCATGGTAGTCAGACCCATACTAACCTATCTGGCAA
 R G E P H Y * M A V P H G S Q T H T N L S G K
 TAGCCTGGGGTGTAGAGCTGCAAAGAATGGCCTGCGTATGCATGCCAGGAGAAATCGTACATGTTCA
 * M H A R R N A Y M F H
 CTGCAGCCCTGAACTAAATGGAGGCGACGCCCTTCATATCGTCAATTCAAATGAAACGGAAAGCCAT
 C C S P *
 CCTAATAAGAATTGAGGGAGCAGGAAATGACTGTAACCTACAAGTAAGGATGCTGAAAGCCTAAAAGG
 M T V T S Q V R M L K A *
 GATATCCCTTGCGAATGCAACCAAGGGATGAGATGCCAGCTGAGCATAGGTTGCTCAGGACATCCCTG
 GTGAAAGTACACCTATGAAAACACAAATAAAGTGGTATACAGACGGATCCCTCACCGACGAGGGAA
 GTGGGCTGGGGTTGTAGGCCGAGGTTAAACACAGAAAAAGTAGGCAGATAAATTTCAGCATTTC
 CATGCTGAAGTCTGTGCTGTTGGACGCTGTGCGGAGTTAATCTGCAAAGGAACATCGTGGCAAGGACA
 M L K S V L L D A V R S L I C K G T I V A R T
 TTTCTATACTGTCTGATAGTCAGCAGCATTAAGGCCTCAGCAAAGCTAACATCTAACAGCTAGT
 F L Y C L I V K Q H *
 AAATGAAGTGAGGACAGCCCTAGACAAACTAGGAGCTGTCACAAACTCACAATAAGGTTGGCCGGGA
 CACAACACATCCCGGAAATGAGCTAGCAGACAACCTAGCAGGAAAGGAGCAGAGAACCCCTAATTG
 GGCCGAACCTCTGTGGTGTGGTCACCACGGAGTACGGGCTGCTAAAGTCACTAGAGGAAGAAAA
 ACGTCTGTTCTGGAACACCTACCAAGGACTTAGGACTCTAACGATTCTACGTGAATAAAAGGTT
 TAAGACCTTAATGACACACGGAAAACACCGTGCCTTACTGGCTTTACGGGCATTGACGA
 M T H G K N T V R I L T G L F T G H *
 CTTCACAGCCATTGCAAGATTGGCATTGAAGACTCTGCTGCACGGAGGAGAGCTCTGCACATA
 TTATATGTGACTGCATGGCGCTTCATCAAGAGGAACAGATTCTCGGCATGTATGTAGTCCCACGGGAA
 M A L Q S R G T D S S A C M *
 M Y V V P R E
 ACAATTGCAGCCCTGAACCCCAATAAAATTCTGGCATTACAGTCATTGGACTTCAGGGGATCTT
 T I A A L N P N K I L A F I Q C I G L Q G D L
 GAGTCATGAAGGGTAGTACAATAGATCTGACTGGTCGAGTACACAGACAAACTAACATAATAAT
 ACTTCATAAGTCAAGCTAACAGAGGCCTGCTTCACAAAGTTCTAGGAAACAGTAATGGCTTAATGG
 * M V F N G
 M
 ACCAACACGAGATTCGAGCAATATAACTAGCCGAACGCTTCCTCCTTGGACACAATGTAAACACAA
 P T R D F E Q Y N *
 D Q H E I S S N I T S R N A F L L W T Q C K H K
 GCACCATAAGCTTAAGGCTAGCATCGCTAACCCATGAATTACACGATCTGAATCTGAGTCCAGCACAA
 H H K P *
 AACGTGGGAATTATCGCTAAAGCTAACAAAGCTAATATCGAGCCATTCTGAGACTCGGG
 TATGCTTAATGCCAGGATAACTCTCCTACAGAGCTGTGAGAAAGATTTACACTTGCAGTACGG
 M T
 TGTCCAAAGTCCAATCGTAAACCTCGCAAGTGAGGATGCCTACCGGAATAAAACTGACCATGTATGAGTT
 C P K S N R K T S Q V R M P T G I N * M Y E F
 M S
 TAGATCAGGAGATCAGGAAATCCAAACGAAGGAATTATACCTCTGGAGGCAATAGTAAACACATG
 R S G D Q E I Q T K E L Y N L L G G N S K H M
 L D Q E I R K S K R R N Y I T F W E A I V N T C
 TGAAGGCCTAGACTCACTGAGCAATCTCAAAGGAGTGACAGAAACTGATCAGCAGCCTAGCTTAGGACT
 *
 E G A R L H *
 GATAACTCTTACTATAGGAAGTAAGGAGAAACTTGAGCTACTACTGGCAACTCACTTCCGGAAAGCA
 CGCTTCAAACGGATGGGAATACCCCGGTAACTGCACAAAGTAGACCGCGTGTACTGATTGGCCAAAGC
 AAAATCACAAGTAACAAACAGAGAGATTAGGATAGGCAAATTGTACATTCCAGCCCTACAAGTCTCCTGGT
 CCAGATGACATTCAAGCCAATCCTGCTCAACGATCAGGAAAGACTGATCAGCAGCCTAGCTTAGGACT
 M T F S Q S C F N D Q E N T D Q Q P S F R T

CATACTACTGCCTGGAGTATAGCAAAAGTGGCTTCATTCCGAAAGCTGGAAAGAAAGACATGACTGAT
 H T Y C L E Y S K S G L H S E S W K E R H D *
 M T D
 CCGAAGTCGTTAGACCATCAGCTTGATATCGTTTGCTAAAACCTGGAAAAGCTAGTGGATGTTAG
 P K S F R P I S L I S F L L K P W K S * M L
 CATTAGAAGCACTCTGCTTGTGGAGCATCCGCTCCAAAGGACGCAGCATGCCTACAGGGCGGGCAGATCA
 A L E A L C L W S I R S K G R S M P T G R A D Q
 ACTGATACTACCCCTATATCACCTGAAAAGCCTTATTGAGGATTCAATGACTCATAAGGAAGTGACGTTAT
 L I L P Y I T * M T H K E V T L M
 GTGCCTCTTAGACATACAGGGTGCTTCGACAATACCTCCCATGAGGCTGTCAACGCATCCCTGGCAAG
 C A F L D I Q G A F D N T S H E A V N A S L A R
 C L L R H T G C F R Q Y L P * M R L S T H P W Q
 AAGAGGACTAGATGCGACAACCAGCAGATGGATTAAATCACTACTGGCATGACCACTGTAGGAGGACAGT
 R G L D A T T S R W I K S L L A *
 E E D * M R Q P A D G L N H Y W H D H C R R T V
 CGTCCACGGTACTTGCTGGTCACTTGCTGGTAGACGAGTTGCTGGACAGACTGACAGGCAGGGTCATT
 V H G T C W S T C W *
 ACAGCTGGAGGTAATATGAGGAAACACTCTGCATATCATTCAACTGGGCCTCGAGTGGTGCAGGAAG
 TAGGCCTGAGAGTAAATCTAGCAAATCTGTTATTGTTCTTCACGAATAGGTACAAGCTACAGAGAAT
 GAAGGCAATAACCTGTCAGAATGTCGATAGAGGCCAGCAAAGAAATTAGTATCTGGATAACCTT
 M S H R G Q Q R N *
 AACTCCAAACTTAGCTCAAAACTCATGTCATAACACAATTGATAATGCACAGAGCACTTTCACGT
 M S I T Q L I N A P E H F S R
 M H Q S T F H V
 GCAGAAAAATTGCTGGTGGTAAGTCGTGGGAAACCTCACTACTAAGATGGCTGTACCTCATGGTAGTCAG
 A E K L L V V S R G E P H Y * M A V P H G S Q
 ACCCATACTAACTTATCTGGCAAATAGCCTGGGTGATAGAGCTGCAAAGAAATGGCCTGCGTATGCATGC
 T H T N L S G K * M H A
 CAGGAGAAATGCGTACATGTTCACTGCAGCCCTGAAAGTACTAATGGAGGCGACGCCGCTTCATATCGT
 R R N A Y M F H C S P *
 CATTCAAATGAAACGGAAAGCCATCTAATAAGAATTGAGGGAGCAGGAAATGACTGTAACCTCACAAAGT
 M T V T S Q V
 AAGGATGCTGAAAGCCTAAAAAGGGATATCCCTTGCATGCAACCAAGGGATGAGATGCCAGCTGAGC
 R M L K A *
 ATAGGTTGCTCAGGACATCCCTGGTCAAAGTACACCCATGAAAACACAAACATAAGTGGTATACAG
 ACGGATCCCTCACCGACGAGGAAAGTGGCTGGGGTTGTAGGCCGAGGTAAACACACGAAAGT
 AGGCAGATAAATTTCAGCATTTCATGCTGAAGTCTGTGCTGTTGGACGCTGTGCGGAGTTAACCTGC
 M L K S V L L D A V R S L I C
 AAAGGAACATCGTGGCAAGGACATTCTATCTGACTGATAGTCAGCAGCATTAAAGGCCTCAGCAA
 K G T I V A R T F L Y C L I V K Q H *
 AGCTAAGATAACATCTAAGTAGTAAATGAAAGTGGAGCACGCCCTAGACAAACACTAGGAGCTGTCAACAAA
 CTCACAATAAGGTTGGTCCCGGGACACAACAAACATCCCGGGAAATGAGCTAGCAGACAAACCTAGCCAGGA
 AAGGAGCAGAGAACCCCTAAATTGGGCCGAACCCCTCTGTGGTGTGGTCACCACGGAGTACGGGGCTT
 GCTAAAGTCACTAGAGGAAGAAAACGCTGTGTTCTGGAACACCTACCAGGACTTAGGCACCTCAAG
 ATTCTCTACGTGAATAAAAGTTAACACACGGAAACACCGTGCCTACAGGAA
 M T H G K N T V R I L T
 GGCCTTTTACGGGGCATTGACGACTTCACAGCCATTGCACAAGATTGGCATTGAAGACTCTGCTGCA
 G L F T G H *
 CGGAGGAGGAGAGCTGACATATTATGTGACTGCATGGCCTCAATCAAGAGGAACAGATTCCCTC
 M A L Q S R G T D S S
 GGCATGTATGTAGTCCCACGGAAACAATTGCAGGCCCTGAACCCCAATAAAATTCTGGCATTACAGT
 A C M *
 M Y V V P R E T I A A L N P N K I L A F I Q
 GCATTGGACTTCAGGGGGATCTTGAGTCATGAAGGGTAGTACAATAGATCTGACTGGTGCAGTACA
 C I G L Q G D L *
 CAGACAAAATCACTTAATAATAACTTCATAAGTCAAGCTAAGAGGCCCTGTTCACAAAGTTTCAGCTT
 AGGAACAGTAATGGCTTAAATGGACCAACACGAGATTCAGCAATATAACTAGCCGAAACGCTTCCT
 M V F N G P T R D F E Q Y N *

M_D_Q_H_E_I_S_S_N_I_T_S_R_N_A_F_L
 CCTTTGGACACAATGTAAACACAAGCACCATAAGCCTTAAGGCTAGCATCGCTAAACCATGAATTACAC
 _L_W_T_Q_C_K_H_K_H_K_P_*
 GATCTGAATCTGAGTCCAGCACAAACGTGGAAATTATCGCTAAAGCTAATACAAAAGCTAATATCGAG
 CCATTCGTATTTGAGACTCGGGTATGCTTAATGCCAGGATAACTTCCTACAGAGCTGTTGCAGA
 AAGATTTACACTTGCGATGACGTGTCAGTCAAAGTCCAATCGTAAACCTCGCAAGTGAGGATGCCTACCG
 M_T_C_P_K_S_N_R_K_T_S_Q_V_R_M_P_T
 GAATAAACTGACCATGTATGAGTTAGATCAGGAGATCAGGAAATCCAACGAAGGAATTATATAACCTT
 G_I_N_* M_Y_E_F_R_S_G_D_Q_E_I_Q_T_K_E_L_Y_N_L
 M_S_L_D_Q_E_I_R_K_S_K_R_R_N_Y_I_T_F
 CTGGGAGGCAATAGTAAACACATGTGAAGGCGCTAGACTTCAGTCAAAGGAGTGACAGAA
 _L_G_G_N_S_K_H_M_*
 W_E_A_I_V_N_T_C_E_G_A_R_L_H_*
 TCAAAATCAGGCACTATGAAAGGAGGATAACTTATAGTAAAGTAAGGAGAAACTTGAGCTACTAC
 TGGCAACTCACTTCCGGGAAGCACGCTCAAACGGATGGAAATACCCCGTAAGTCACAAAGTAGACC
 GCGTGCTACTGATTGGGCCAAAGCAAACAGTAACAACAGAGAGATTAGGATAGGCAAATTGTACA
 TTCCAGCCCTACAAGTCTCCTGGTCCAGATGACATTAGCCAATCCTGTTCAACGATCAGGAAATACT
 M_T_F_S_Q_S_C_F_N_D_Q_E_N_T
 GATCAGCAGCCTAGCTTAGGACTCATACCTACTGCCTGGAGTATAGCAAAGTGGTCTTCATTCCGAA
 _D_Q_Q_P_S_F_R_T_H_T_Y_C_L_E_Y_S_K_S_G_L_H_S_E
 GCTGGAAAGAAAGACATGACTGATCCGAAGTCGTTAGACCCATCAGCTTGTATCGTTTGCTAAAC
 S_W_K_E_R_H_D_*
 M_T_D_P_K_S_F_R_P_I_S_L_I_S_F_L_L_K
 CTTGGAAAAGCTAGTGGATGTTAGCATTAGAACACTCTGCTTGAGCATCCGCTCAAAGGACGCAG
 P_W_K_S_* M_L_A_L_E_A_L_C_L_W_S_I_R_S_K_G_R_S
 CATGCCTACAGGGCGGGCAGATCAACTGATACTACCCATATCACCTGAAAAGCCTTATTGAGGATTCAA
 M_P_T_G_R_A_D_Q_L_I_L_P_Y_I_T_*
 TGACTCATAGGAAAGTGCCTTATGTGCCTTCTAGACATACAGGGTGCCTCGACAATACCTCCATGA
 M_T_H_K_E_V_T_L_C_A_F_L_D_I_Q_G_A_F_D_N_T_S_H_E
 M_C_L_L_R_H_T_G_C_F_R_Q_Y_L_P_*
 M
 GGCTGTCAACGCATCCCTGGCAAGAAGAGGACTAGATGCGACAACCAGCAGATGGATTAAATCACTACTG
 _A_V_N_A_S_L_A_R_R_G_L_D_A_T_T_S_R_W_I_K_S_L_L
 R_L_S_T_H_P_W_Q_E_E_D_* M_R_Q_P_A_D_G_L_N_H_Y_W
 GCATGACCACTGTAGGAGGACAGTCGTCACGGTACTTGCTGGTACTTGCTGGTAGACGAGTTGCTGG
 A_*
 H_D_H_C_R_R_T_V_V_H_G_T_C_W_S_T_C_W_*
 ACAGACTGACAGGCAGGGGTCTTACAGCTGGAGGTAATATGAGGAAACACTCTGCGATATCATTCAAC
 TGGGCCTCGAGTGGTCAAGGAAGTAGGCCTGAGAGTAAATCTAGCAAATCTGTATTGTTCTTTCAC
 GAATAGGTACAAGCTACAGAGAATGAAGGCAATAACCTGTCAGAATGTCGATAGAGGCCAGCAAAGAA
 M_S_H_R_G_Q_Q_R
 ATTAAGTATCTTGGATAACCTTAACCTAACTCCAAACTTAGCTCAAACACTCATGTCGATAACACAATTGATA
 N_* M_S_I_T_Q_L_I
 AATGCACCAAGAGCACTTTCACGTGCAGAAAAATTGCTGGGGTAAGTCGTGGGGAACCTCACTACTAAG
 _N_A_P_E_H_F_S_R_A_E_K_L_L_V_V_S_R_G_E_P_H_Y_*
 M_H_Q_S_T_F_H_V_Q_K_N_C_W_W_*
 ATGGCTGTACCTCATGGTAGTCAGACCCATACTAACTTATCTGGCAAATAGCCTGGGGTGTAGAGCTGC
 M_A_V_P_H_G_S_Q_T_H_T_N_L_S_G_K_*
 AAAGAATGGCCTGCGTATGCGTACATGCTGGAGAAATGCGTACATGTTCACTGCAGCCCTGAAAGTACTAAT
 M_H_A_R_R_N_A_Y_M_F_H_C_S_P_*
 GGAGGCAGGCCGCTTCATCGTCATTCAAATGAAACGGAAAGCCATCCTAATAAGAATTGAGGGAGCA
 GGAAATGACTGTAACCTCACAAGTAAGGATGCTGAAAGCCTAAAAGGGATATCCCTTGCGAATGCAAC
 M_T_V_T_S_Q_V_R_M_L_K_A_*
 CAAGGGATGAGATGCCAGCTGAGCATAGGTTGCTCAGGACATCCCTGGTAAAGTACACCCCTATGAAAA
 CACAAACAATAAAGTGGTATACAGACGGATCCCTACCGACGAGGGAAAGTGGCTGGGGTTGAGGCCG
 CAGGTTAAAATACCAAGAAAAAGTAGGCAGATAAATTTCAGCATTTCATGCTGAAGTCTGTGCTGTTG
 M_L_K_S_V_L_L
 GACGCTGTGCGGAGTTAATCTGCAAAGGAACATCGTGGCAAGGACATTCTATAGTCTGATAGTCA
 D_A_V_R_S_L_I_C_K_G_T_I_V_A_R_T_F_L_Y_C_L_I_V
 AGCAGCATTAAAGGCGCTCAGCAAAGCTAAGATAACATCTAAGCTAGTAAATGAAGTGGAGGACAGCCCTA
 K_Q_H_*

GACAAACTAGGAGCTGTCAACAAACTACAATAAGGTTGGTCCCGGGACACAACACATCCCGGGAAATG
 AGCTAGCAGACAACCTAGCCAGGAAAGGAGCAGAGAACCCCTAATTGGGCCGAACCCTCTGTGGTGT
 TGGTCACCACGGAGTACGGGCTTGCTAAAGTCACTAGAGGAAGAAAACGTCTGTTCTGGAACAC
 CTACCAGGACTTAGGCACTCTAAGATTCTTACGTGAATAAAAGGTTAAGACCTTAATGACACACGGG
 M T H G
 AAAAACACCGTGCGCATTTGACTGGCCTTTACGGGGCATTGACGACTTCACAGCCATTGACAGAAGA
 K N T V R I L T G L F T G H *
 TTGGCATTGAAGACTCTGCTGCACGGAGGAGCTGCACATATTATATGTGACTGCATGGCGCT
 M A L
 TCAATCAAGAGGAACAGATTCTCGGCATGTATGTAGTCCCACGGAAACAATTGCAGCCCTGAACCCCA
 Q S R G T D S S A C M *
 M Y V V P R E T I A A L N P
 ATAAAATTCTGGCATTATACAGTCATGGACTTCAGGGGATCTTGAGTCATGAAGGGTAGTACAA
 N K I L A F I Q C I G L Q G D L *
 TAGATCTGACTGGGTCGAGTACACAGACAAATCACTTAATAATAACTTCATAAGTCAAGCTAAGAG
 GCCTGCTTCACAAAGTTCAGCTTAGAACAGTAATGGTCTTAATGGACCAACACGAGATTCGAGCAA
 M V F N G P T R D F E Q
 M D Q H E I S S N
 TATAACTAGCCGGAACGCTTCCTCCTTGGACACAATGTAACACACAGCACCATAAGCCTAAGGCTAG
 Y N *
 I T S R N A F L L W T Q C K H K H H K P *
 CATCGCTAAACCCATGAATTACAGATCTGAATCTGAGTCAGCACAAACAGTGGGAATTATCGCTAAA
 GCTAATACAAAAGCTAATATCGAGCCATTCTGTTGAGACTCGGGTATGCTTAATGCCAGGATAAC
 TTCTCCTTACAGAGCTGTTGCAGAAAGATTACACTTGCATGACGTGTCCTAAAGTCCAATCGTAAAAA
 M T C P K S N R K
 CCTCGCAAGTGAGGATGCCTACCGGAATAAAACTGACCATGTATGAGTTAGATCAGGAGATCAGGAAATC
 T S Q V R M P T G I N * M Y E F R S G D Q E I
 M S L D Q E I R K S
 CAAACGAAGGAATTATATAACCTCTGGGAGGCAATAGTAAACACATGTGAAGGCCTAGACTTCACTGA
 Q T K E L Y N L L G G N S K H M *
 K R R N Y I T F W E A I V N T C E G A R L H *
 GCAATCTCCAAGGAGTGACAGAAATCAAATCAGGCACTATGAAAGGAGGATAACTCTTATACTATAGGAA
 GTAAGGAGAAACTTGAGCTACTACTGGCAACTCACTTCCGGGAAGCACGCTCAAACGGATGGGAAATAC
 CCCGGTAACTGCACAAAGTAGACCGCGTGCTACTGATTGGCCAAGCAGAAATCACAAGTAACAACAGAG
 AGATTAGGATAGGCAAATTGTACATTCCAGCCCTACAAGTCTCTGGTCAGATGACATTAGCCAATCC
 M T F S Q S
 TGCTTCAACGATCAGGAAAATACTGATCAGCAGCCTAGCTTAGGACTCATACCTACTGCCTGGAGTATA
 C F N D Q E N T D Q Q P S F R T H T Y C L E Y
 GCAAAAGTGGTCTTCATTCCGAAAGCTGGAAAGAACATGACTGATCCGAAGTCGTTAGACCCATCA
 S K S G L H S E S W K E R H D *
 M T D P K S F R P I
 GCTTGATATGTTTGCTAAACCTGGAAAGCTAGTGGATGTTAGCATTAGAACACTCTGCTTGTG
 S L I S F L L K P W K S * M L A L E A L C L W
 GAGCATCCGCTCCAAAGGACGCAGCATGCCTACAGGGCGGGCAGATCAACTGATAACTACCCATATCACC
 S I R S K G R S M P T G R A D Q L I L P Y I T
 TGAAAAGCCTTATTGAGGATTCAATGACTCATAAGGAAGTGAACGTTATGTGCTCTTAGACACATACAGGG
 * M T H K E V T L C A F L D I Q G
 M C L L R H T G
 TGCTTCGACAATACCTCCATGAGGCTGTCAACGCATCCCTGGCAAGAACAGGAGACTAGATGCGACAACC
 A F D N T S H E A V N A S L A R R G L D A T T
 C F R Q Y L P * M R L S T H P W Q E E D * M R Q P
 AGCAGATGGATTAAATCACTACTGGCATGACCACTGTAGGAGGACAGTCGTCACGGTACTTGCTGGTCT
 S R W I K S L L A *
 A D G L N H Y W H D H C R R T V V H G T C W S
 ACTTGCTGGTAGACGAGTTGCTGGACAGACTGACAGGGCAGGGTCATTACAGCTGGAGGTAAATATGAGG
 T C W *
 AACACTCTGCGATATCATTCAACTGGGCCTCGAGTGGTCAAGGAAGTAGGCCTGAGAGTAAATCCTAG
 CAAATCTGTTATTGTTCTTCACGAATAGGTACAAGCTACAGAGAACAGCAATAACCCTGTCAGAA
 TGTCGATAGAGGCCAGCAAAGAAATTAGTATCTGGATAACCCTTAACCTAGCTTCAAAA
 M S H R G Q Q R N *

CTCATGTCGATAACACAATTGATAAATGCACCAGAGCACTTTCACGTGCAGAAAAATTGCTGGTGGTAA
 M_S_I_T_Q_L_I_N_A_P_E_H_F_S_R_A_E_K_L_L_V_V_
 M_H_Q_S_T_F_H_V_Q_K_N_C_W_W_*
 GTCGTGGGAACCTCACTACTAACAGATGGCTGTACCTCATGGTAGTCAGACCCATACTAACTTATCTGGCA
 S_R_G_E_P_H_Y_* M_A_V_P_H_G_S_Q_T_H_T_N_L_S_G
 ATAGCCTGGGTGATAGAGCTGCAAAGAATGGCCTCGTATGCATGCCAGGAGAAATGCGTACATGTT
 K_* M_H_A_R_R_N_A_Y_M_F
 CACTGCAGCCCTGAAGTACTAACATGGAGGCGACGCCGCTTCATATCGTCAATTCAAATGAAACGGAAAGCC
 H_C_S_P_*
 ATCCTAATAAGAATTGAGGGAGCAGGAAATGACTGTAACCTACAAGTAAGGATGCTGAAAGCCTAAAAA
 M_T_V_T_S_Q_V_R_M_L_K_A_*
 GGGATATCCCTTGCATGCAACCAAGGGATGAGATGCCAGCTGAGCATAGGTTGCTCAGGACATCCC
 TGGTAAAGTACACCCATGAAAACACAAATAAAAGTGGTATACAGACGGATCCCTCACCGACGAGGG
 AAGTGGCTGGGGTTGTAGGCCGAGGTTAAATACCACGAAAAGTAGGCAGATAAATTTCAGCATT
 TTCACTGCTGAAGTCTGTGCTGTTGGACGCTGTGCGGAGTTAACAGAAACTATCGTGGCAAGGA
 M_L_K_S_V_L_D_A_V_R_S_L_I_C_K_G_T_I_V_A_R
 CATTCTATRACTGCTGATAGTCAGCAGCATTAAGGCCTCAGCAAAGCTAACAGATAACATCTAACGTA
 T_F_L_Y_C_L_I_V_K_Q_H_*
 GTAAATGAAGTGAGGACAGCCCTAGACAAACTAGGAGCTGTCACAAACTACAATAAGGTTGGTCCC
 GACACAAACACATCCCGGAAATGAGCTAGCAGACAACCTAGCCAGGAAAGGAGCAGAGAACCCCTAAT
 TGGGCCGAACCCCTCTGTGGTGTGGTACCCAGGAGTACGGGCTGCTAAAGTCACTAGAGGAAGAA
 AACGTCGTTCTGGAACACCTACCAGGACTTAGGACTCTAACAGATTCTTACGTGAATAAAGG
 TTTAAGACCTTAATGACACACGGAAAACACCGTGCCTTTGACTGGCTTTACGGGCATTGAC
 M_T_H_G_K_N_T_V_R_I_L_T_G_L_F_T_G_H_*
 GACTTCACAGCCATTGCACAAGATTGGCATTGAAGAGACTTCTGCTGCACGGAGGAGAGCTCTGCACA
 TATTATATGTGACTGCATGGCGCTCAATCAAGAGGAACAGATTCCCTGGCATGTATGAGTCCCACGGG
 M_A_L_Q_S_R_G_T_D_S_S_A_C_M_*
 M_Y_V_V_P_R
 AAACAATTGCAGCCCTGAACCCAATAAAATTCTGGCATTATACAGTCATTGGACTTCAGGGGATCT
 E_T_I_A_A_L_N_P_N_K_I_L_A_F_I_Q_C_I_G_L_Q_G_D_L
 TTGAGTCATGAAGGGTAGTACAATAGATCTGACTGGCTCGAGTACACAGACAAATCACTTAATAA
 *
 ATACTTCATAAGCTAACAGGGCTGTTCACAAAGTTTAGGAAACAGTAATGGCTTTAAT
 M_V_F_N_M
 GGACCAACACGAGATTCGAGCAATATAACTAGCCGAACGCTTCCTCCTGGACACAATGAAACAC
 G_P_T_R_D_F_E_Q_Y_N_*
 D_Q_H_E_I_S_S_N_I_T_S_R_N_A_F_L_L_W_T_Q_C_K_H
 AAGCACCCATAAGCCTTAAGGCTAGCATCGCTAACCCATGAATTACACGATCTGAATCTGAGTCCAGCAC
 K_H_H_K_P_*
 AAAACGTGGAAATTCATGCTAAAGCTAACAAAGCTAACATCGAGCCATTCTGTTGAGACTCG
 GGTATGCTTAATGCCAGGATAACTCTCCTACAGAGCTGTGAGAAAGATTACACTTGCATGA
 M
 CGTGTCCAAAGTCCAATCGAACACCGTACAGGAAATTATACGCTGGAGGCAATAGTAAACACA
 T_C_P_K_S_N_R_K_T_S_Q_V_R_M_P_T_G_I_N_* M_Y_E_
 M_S
 TTTAGATCAGGAGATCAGGAAATCCAAACGAAGGAATTATACGCTGGAGGCAATAGTAAACACA
 F_R_S_G_D_Q_E_I_Q_T_K_E_L_Y_N_L_L_G_G_N_S_K_H
 L_D_Q_E_I_R_K_S_K_R_R_N_Y_I_T_F_W_E_A_I_V_N_T
 TGTGAAGGCCTAGACTCACTGAGCAATCTCAAAGGAGTGCAGAACATCAGGACTATGAAAGG
 M_*
 C_E_G_A_R_L_H_*
 AGGATAACTCTTATACATAGGAAGTAAGGAGAAACTTGAGCTACTACTGGCAACTCACTTCCGGAAAG
 CACGCTTCAAACGGATGGGAATACCCCGGTAAGTGCACAAAGTAGACCGCGTGTACTGATTGGCCAAA
 GCAAATCACAAGTAACAACAGAGAGATTAGGATAGGCAAATTGTACATTCCAGCCTACAAGTCTCTG
 GTCCAGATGACATTCAAGCAATCCTGCTCAACGATCAGGAAATACTGATCAGCAGCCTAGCTTAGGA
 M_T_F_S_Q_S_C_F_N_D_Q_E_N_T_D_Q_Q_P_S_F_R
 CTCATACCTACTGCTGGAGTATAGCAAAGTGGCTTCATTCCGAAAGCTGGAAAGAAAGACATGACTG
 T_H_T_Y_C_L_E_Y_S_K_S_G_L_H_S_E_S_W_K_E_R_H_D_*
 M_T
 ATCCGAAGTCGTTAGACCCATCAGCTGATATCGTTTGCTAAACCTGGAAAGCTAGTGGATGTT

D_P_K_S_F_R_P_I_S_L_I_S_F_L_L_K_P_W_K_S_* M_L
 AGCATTAGAAGCACTCTGCTTGTGGAGCATCCGCTCCAAAGGACGCAGCATGCCTACAGGGCGGGCAGAT
 _A_L_E_A_L_C_L_W_S_I_R_S_K_G_R_S_M_P_T_G_R_A_D
 CAACTGATACTACCCCTATATCACCTGAAAAGCCTTATTGAGGATTCAATGACTCATAAGGAAGTGACGTT
 Q_L_I_L_P_Y_I_T_* M_T_H_K_E_V_T_L
 ATGTGCCTTCTTAGACATACAGGGTGCTTCGACAATACCTCCATGAGGCTGTCAACGCATCCCTGGCA
 _C_A_F_L_D_I_Q_G_A_F_D_N_T_S_H_E_A_V_N_A_S_L_A
 M_C_L_L_R_H_T_G_C_F_R_Q_Y_L_P_* M_R_L_S_T_H_P_W_Q
 AGAAGAGGACTAGATGCGACAACCAGCAGATGGATCAAATCACTACTGGCATCACTACAGTATCCACCAC
 _R_R_G_L_D_A_T_T_S_R_W_I_K_S_L_L_A_*
 _E_E_D_* M_R_Q_P_A_D_G_S_N_H_Y_W_H_H_Y_S_I_H_H
 M_D_Q_I_T_T_G_I_T_T_V_S_T_T
 AAGGGGTTAACCAAGGGGTGTCCTCTCGCCTCTCCTGTGCAGCTGCTGGACAGACTGACCCGCATGGG
 _K_G_L_T_K_G_V_S_S_R_L_S_C_A_A_C_W_T_D_*
 _R_G_*
 TATACTTTGCCAAGGCTATGCTGACCATATTGTCATTATAGCTAGCTTAGGCCTGAGCCTAAATCCTGG
 CAAAACGTATTGTCCTTCACAAATAGGTACAAGCTACAGAGAATAAAGGAATAACCCTGTCAGAA
 TGTCGATAGAGGTCAACAAAGAAGTTAAGTATCTGGATAACCCTGACTCCAAACTTAGCTTCAAAA
 M_S_H_R_G_Q_Q_R_S_*
 CTCATGTCATAACACAATTGATAAGTGCACCAGAGCAATTACACGTGAGCTTAACTGCAAAGGAACATCG
 AACAGTTGGACATCCCTGTGGAAAGTAACCACAAATAAGTGGTATACAGATGGATCCCTC
 M_D_P_S
 ACCGACGAGGGAAAGTGGCTGGGGTTGTTAGGCCCCATGTTGAAATACACGAATCAATGGCAGATA
 P_T_R_E_V_G_W_G_L_*
 CCAGCATTTCAGCTGAAGCCTATGCTATTGGACGCTGTGCAGAGTTAATCTGCAAAGGAACATCG
 M_L_L_D_A_V_Q_S_L_I_C_K_G_T_I
 TGACAAGGACATTGATATACTGTCGATAGTCAGCAGCCATAAGGCCTCAGCAAAGCTAAGATAACA
 V_T_R_T_L_I_Y_C_L_I_V_K_Q_P_*
 TCTAAGCTAGTAAATGAAGTGAGAACAGCCCCAGACAAACTAGGAGCTGTCAACAAACTACAATAAGGT
 GGGTCCCGGGACACAACACATCCCGGAAATGAGCTAGCGGACAACCTAGCCAGGAAGGGCCAGAGAA
 CCCTCTAATTGGGCCGAACATTCTGTTGGTCACCACAGAGTACTGGCTACTTAAGTCAATAG
 CGGAAGAAAAACGTCTGCTCTGGAACACCTACCGGACTTAGGCAGTCTAAGATTCTCCCTCGTGA
 ATATAACCATAAAAGGTTCAAGACCTTAATGACATACGGGAAAACACCGTGCACGTTGACTGGCCTT
 CTTACGGGCATTGCCACTTCACGCCATTGCAAGATTGGCATTGAAGACTCTGCTGCACGGAGG
 AGGAGAGCTCAGCACATATTATGTGACTGCATGGCGCTCAATCAAGAGGAACAGATTCTCGGCATG
 M
 TATGTAGTCCCACGGAAACAATTACCCAATAAAATTCTGGCATTATACAGTGCATTGGACTTCAGGG
 Y_V_V_P_R_E_T_I_T_P_I_K_F_W_H_L_Y_S_A_L_D_F_R
 GGATCTTGAGTCATGAAGGGTAGTACAATAGATCTGACTGGGTCGAGTACACAGACAAACTCACTTA
 G_I_F_E_S_*
 ATAATAATACTTCATAAGCTAAGAGGCCTGCTCACAAAGTTCAGCTTAGGAACAGTAATGGC
 M_V
 TTTAATGGACCAACACGAGATTCGAGCAATATAACTAGCCGAACGCTTCCTCCTTGGACACAATGT
 F_N_G_P_T_R_D_F_E_Q_Y_N_*
 M_D_Q_H_E_I_S_S_N_I_T_S_R_N_A_F_L_L_W_T_Q_C
 AAACACAAGCACCATAAAGCCTAAGGCTAGCATCGCTAACCCATGAATTACACGATCTGAATCTGAGTC
 K_H_K_H_H_K_P_*
 CAGCACAAAACGTGGAAATTGCTGCTAAAGCTAATACAAAGCTAATATCGAGCCATTGCTTGA
 GACTCGGGTATGCTTAATGCCAGGAACTTCTCCTACAGAGCTGTGCAGAAAGATTACACTTTG
 CGATGACGTGTCCAAAGTCCAATCGTAAACCTCGCAAGTGAGGATGCCTACCGGAATAACTGACCATG
 M_T_C_P_K_S_N_R_K_T_S_Q_V_R_M_P_T_G_I_N_* M
 TATGAGTTAGATCAGGAGATCAGGAAATCCAAACGAAGGAATTATATAACCTCTGGGAGGCAATAGTA
 Y_E_F_R_S_G_D_Q_E_I_Q_T_K_E_L_Y_N_L_L_G_G_N_S
 M_S_L_D_Q_E_I_R_K_S_K_R_R_N_Y_I_T_F_W_E_A_I_V
 AACACATGTGAAGGCCTAGACTTCACTGAGCAATCTCAAAGGAGTGACAGAATCAAATCAGGCACAT
 K_H_M_*
 N_T_C_E_G_A_R_L_H_*
 GAAAGGAGGATAACTCTTATACATAGGAAGTAAGGAGAAACTTGAGCTACTACTGGCAACTCACTTCC
 GGGAGCACGCTTCAAACGGATGGAAATACCCGGTAACTGCACAAAGTAGACCGCGTGTACTGATTGG

```

GCCAAAGCAAAATCACAGTAACAACAGAGAGATTAGGATAAGCAAATTGTACATTCCAGCCCTACAAGT
CTCCTGGTCCAGATGACATTAGCCAATCCTGCTCAACGATCAGGAAAATACTGATCAGCAGCCTAGCT
M_T_F_S_Q_S_C_F_N_D_Q_E_N_T_D_Q_Q_P_S_
TTAGGACTCATACCTACTGCCTGGAGTATAGCAAAGTGGTCTTCATTCCGAAAGCTGGAAAGAAAGACA
F_R_T_H_T_Y_C_L_E_Y_S_K_S_G_L_H_S_E_S_W_K_E_R_H
TGACATGACTGATCCGAAGTCGTTAGACCCATCAGCTGATATCGTTTGCTAAAACCTTGGA
D *
M_T_D_P_K_S_F_R_P_I_S_L_I_S_F_L_L_K_P_W_K_S *

```

Para el gen 2R_96, el programa Augustus Gene Prediction predijo una estructura compuesta por 13 exones de 425 pares de bases el primero, 175 pares de bases el segundo, 186 pares de bases el tercero, 212 pares de bases el cuarto, 175 pares de bases el quinto, 217 pares de bases el sexto, 88 pares de bases el séptimo, 175 pares de bases el octavo, 217 pares de bases el noveno, 88 pares de bases el décimo, 175 pares de bases el decimoprimero, 107 pares de bases el decimosegundo, y 620 pares de bases el decimotercero, y 12 intrones de 2023 pares de bases el primero, 507 pares de bases el segundo, 2317 pares de bases el tercero, 2023 pares de bases el cuarto, 1756 pares de bases el quinto, 1626 pares de bases el sexto, 113 pares de bases el séptimo, 1756 pares de bases el octavo, 1626 pares de bases el noveno, 113 pares de bases el décimo, 153 pares de bases el decimoprimero, y 53 pares de bases el decimosegundo.

Se encontró acuerdo con espectros de masas para el péptido DQITTGITT VSTTR con una probabilidad de $p=0.042$ y un valor $E=0.000102560808637565$; para el péptido TLIYCLIVK con una probabilidad de $p=0.058$ y un valor $E=0.000731119522471778$; para el péptido SLDQEIRK con una probabilidad de $p=0.002$ y un valor $E=0.000191118927747795$; para el péptido MSITQLINAPEHFSR con una probabilidad de $p=0.035$ y un valor $E=9.18080278409815e-05$; para el péptido SITQLINAPEHFSR con una probabilidad de $p=0.016$ y un valor $E=9.66773360525004e-05$; para el péptido ELYNLLGGNSKHM con una probabilidad de $p=0.007$ y un valor $E=0.000134877430120634$; para el péptido RQPADGSNHYWHHSIHHK con una probabilidad de $p=0.006$ y un valor $E=0.000917922108684765$; para el péptido SPSQGTLQSSPTKK con una probabilidad de $p=0.054$ y un valor $E=0.000734166497450426$.

En esta región genómica se observa la pauta de sORFs separados por secuencias pequeñas (<2 kbp) como las que se esperan para mensajeros policistrónicos basados en *tal*. En este caso se observan una serie de 121 sORFs. Se pueden observar repeticiones. No se observa presencia de ESTs, con lo cual no se halla evidencia de transcripción. La probable traducción se basa en la presencia en bases de datos de 8 péptidos definidos por espectrometría de masas que cumplirían con los requisitos mínimos establecidos en este trabajo ($E < 0,001$) para su validación.

La falta de evidencia de traducción de los demás sORFs no significa que no sean traducidos. Para validarlos, sería necesaria la realización de un análisis extensivo por espectrometría de masas que excede el objetivo de este trabajo final de licenciatura, pero que forma parte del plan de tesis que se llevará a cabo más adelante. Por lo tanto se considera que esta es una posible región expresada del genoma y aún no anotada.

DISCUSIÓN Y CONCLUSIONES

Los resultados de este trabajo demuestran que ORFs no canónicos (< 100 codones=sORFs) efectivamente existen en el cromosoma 2 de *Drosophila melanogaster*, codificando pequeños péptidos funcionales. Los sORFs analizados en el presente estudio están codificados por ARNs mensajeros muy posiblemente policistrónicos, separados por secuencias pequeñas (<2 kpb), en donde la disposición de genes en un grupo funcional constituye un operón porque opera como una unidad a partir de un único promotor, al igual que los operones encontrados en organismos procariotas. De todos modos no se puede descartar *a priori* que dichos sORFs puedan formar parte de transcriptos independientes. De todos modos la disposición en clusters sugiere fuertemente una estructura similar a la descripta para *tal*.

El análisis bionformático utilizado, el cual es novedoso, permitió descubrir 33 loci aún no anotados y con una probable estructura génica coherente. En cada una de esas regiones existen diferentes sORFs codificantes de pequeños péptidos, muchos de los cuales poseen evidencia de expresión de acuerdo a lo encontrado en las bases de datos de espectros de masas y, por otro lado, en bases de datos de ESTs. La evidencia en espectros de masas establece la probable traducción de dichos sORFs, y la evidencia de ESTs hace referencia a la evidencia de transcripción. La ausencia de evidencia de traducción de los demás sORFs no significa que no sean traducidos, pero con el criterio de selección estricta usada en este trabajo, no fueron analizados.

Estos resultados están en concordancia con los descriptos para el gen *tarsal-less* (8) descubierto en el genoma de *Drosophila melanogaster*. La función de *tal* es mediada por varios ORFs de 33 nucleótidos, siendo de esta manera un sORF policistrónico. Cuatro de los cinco péptidos codificados por *tal* poseen una secuencia muy similar, tal como observamos en nuestros genes, conteniendo un motivo proteico conservado

(LDPTGXY). La existencia de sólo uno de estos cuatro péptidos alcanza para proveer la función completa de *tal*. La presencia de estos sORFs repetidos es una estrategia para asegurar una traducción suficiente de péptidos que contengan el motivo LDPTGXY. En el presente trabajo se observan también repeticiones de sORFs que podrían cumplir una función similar a la de los péptidos repetidos en *tal*. De esta manera, se demuestra que los pequeños péptidos codificados por sORFs efectivamente existen en el genoma de *Drosophila melanogaster*, pudiendo cumplir funciones biológicas de vital importancia. En este trabajo se sientan las bases para el análisis funcional de cada uno de estos genes. Todos los genomas secuenciados y anotados contienen genes y transcriptos sin función conocida. En particular, un número creciente de transcriptos están siendo clasificados como no codificantes (ncRNA) sobre la base de no tener ORFs evidentes. Sin embargo esto se basa en la incapacidad de los sistemas de anotación automática de detectar dichos ORFs. En este sentido, este trabajo es una importante contribución para el descubrimiento de nuevos genes con métodos de predicción novedosos. Es destacable que los genomas contienen cientos de miles de sORFs potenciales que son sistemáticamente eliminados de las anotaciones génicas por razones estadísticas.

Bibliotecas de ADN complementario (ADNc) y colecciones de ESTs también discriminan contra pequeños ADN complementarios, perdiendo así muchos transcriptos potenciales. Es por eso, por ejemplo, que los micro RNAs solo fueron descubiertos muy recientemente y, tal como en el caso de los sORFs su predicción es tan compleja.

Los pequeños péptidos conocidos cumplen importantes funciones biológicas, mayormente en la comunicación neural y endocrina, pero en todos los casos descriptos esos péptidos son productos maduros, clivados de un ORF mayor. En otros casos, como el de la insulina o histonas, para dar dos ejemplos, la anotación se basó en el conocimiento previo de las proteínas, antes de la era de la genómica. La originalidad de

el trabajo presentado aquí radica en la comprobación de la existencia de péptidos menores a 100 aminoácidos en el genoma de *Drosophila melanogaster*, y en que tales péptidos son codificados por ARN mensajeros policistrónicos, donde varios ORFs se traducirían a partir de una única molécula de ARN mensajero.

Este trabajo demuestra que pequeños péptidos codificados por sORFs pueden ser descubiertos y analizados utilizando herramientas bioinformáticas, con una metodología novedosa y menos restrictiva para la búsqueda de genes.

Ha sido demostrado que sORFs existen en *Drosophila* y en *S. cerevisiae*, lo que abre la posibilidad de la existencia de estos genes en vertebrados superiores. El número de genes codificantes de pequeños péptidos en el genoma de *Drosophila* es elevado, lo cual demuestra la probabilidad de la presencia de muchos más genes que los descubiertos en este trabajo. En los procesos de anotación existe una cantidad creciente de transcriptos clasificados como no codificantes, y por lo tanto, son pasados por alto, sin ser analizada su posible traducción. Una búsqueda sistemática de péptidos codificados por sORFs permitirá el descubrimiento de nuevos genes. Esta fase del trabajo excede el objetivo de un trabajo final de licenciatura por su complejidad y extensión, pero a la vez, este trabajo permite iniciar estudios funcionales complejos en este y otros organismos.

Bibliografía citada

- (1) Lacadena Juan Ramón, Citogenética, 1^a Edición, marzo 1996, Editorial complutense.
- (2) Lacadena Juan Ramón, Citogenética, 1^a Edición, marzo 1996, Editorial complutense.
- (3) Crollius, H. R., et al, 2000, Estimate of Human Gene Number Provided by Genome-Wide Analysis Using *Tetraodon nigroviridis* DNA Sequence, *Nature Genetics* **25**, 235-38; Ewing, B. and P. Green, 2000, Analysis of Expressed Sequence Tags Indicates 35,000 Human Genes, *Nature Genetics* **25**, 232-34; Liang, F., et al, 2000, Gene Index Analysis of the Human Genome Estimates Approximately 120,000 Gene, *Nature Genetics* **25**, 239-40.
- (4) Kastenmayer James P., Ni Li Chu Angela, Kitchen Lauren E., Au Wei-Chun, Yang Hui, Carter Carole D., Wheeler David, Davis Ronald W., Boeke Jef D., Snyder Michael A. and Basrai1 Munira A., 2006, Functional genomics of genes with small open reading frames (sORFs) in *S. Cerevisiae*, 16:365–373 ISSN 1088-9051/06.
- (5) Yang Xiaohan, J. Tschaplinski Timothy, Hurst Gregory B., Jawdy Sara, Hettich Robert L., Lindquist Erika, Kalluri Udaya C., Gunter Lee E., Pennacchio Christa and Abraham Paul E., Lankford Patricia K., Adams Rachel M., Shah Manesh B., Tuskan Gerald A., 2011, Discovery and annotation of small proteins using genomics, proteomics, and computational approaches, *Genome Research* 21:000–000 ISSN 1088-9051/11.
- (6) Galindo Máximo Ibo, Pueyo José Ignacio, Fouix Sylvaine, Bishop Sarah Anne and Couso Juan Pablo, 2007, Peptides Encoded by Short ORFs Control Development and Define a New Eukaryotic Gene Family, *PLoS Biology* 5(5): e106. doi:10.1371/journal.pbio.0050106.
- (7) Pueyo Jose Ignacio, Couso Juan Pablo, The 11-aminoacid long Tarsal-less peptides trigger a cell signal in *Drosophila* leg development, 2008, *Developmental Biology* 324 192-201 doi:10.1016/j.ydbio.2008.08.025.
- (8) Kondo T., Plaza S., Zanet J., Benrabah E., Valenti P., Hashimoto Y., Kobayashi S., Payre F., Kageyama1 Y., Small Peptides Switch the Transcriptional Activity of Shavenbaby During *Drosophila* Embryogenesis, 2010, *Science* Vol. 329 336-339.

RESUMEN

El número de genes que codifican proteínas en eucariotas superiores identificados por proyectos de genoma es más bajo que lo esperado, mientras que ha sido detectada una considerable cantidad de transcriptos putativamente no codificantes. Esto refleja, nuevamente, las limitaciones de los sistemas predictivos. Pero en caso de ser correctas, ¿cómo es posible que la enorme variabilidad fenotípica de los organismos tenga como origen un pequeño número de genes mayormente conservados? Varias respuestas han sido propuestas: interacciones génicas complejas, splicing alternativo, y genes no codificantes. Otra posibilidad menos discutida podría ser muchos genes no canónicos y por lo tanto no identificados, escapen a la detección de los programas de anotación génica.

Algunos métodos de detección génica y anotación permiten encontrar genes con sORFs (pequeños marcos abiertos de lectura, del inglés *small open reading frames*) que codificarían pequeños péptidos, los cuales esperan caracterización.

En el presente trabajo se analizó el genoma del cromosoma 2 de *Drosophila melanogaster* en busca de sORFs codificados en ARNs policistrónicos, descubriéndose que los sORFs efectivamente existen en el genoma de *Drosophila*. Se utilizaron métodos bioinformáticos novedosos que permitieron detectar dichos genes.

ANEXOS

Abreviatura de aminoácidos utilizada:

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