

MIDAS: Aplicación informática para la identificación de microsatélites exactos e inexactos en secuencias genómicas.

MIDAS: Computer application for the identification of exact and inaccurate microsatellites in genomic sequences.

Carlos M. Martínez Ortiz^{1*}

¹Departamento de Bioquímica, Universidad de Ciencias Médicas, ICPB “Victoria de Girón”, La Habana, Cuba

*Correspondencia: cmmo@infomed.sld.cu

RESUMEN

Los microsatélites son secuencias cortas repetidas en tándem, frecuentes y diversas en los genomas de todas las especies, constituyendo importantes marcadores en múltiples áreas de investigación basadas en la genómica. Se han encontrado asociaciones de estos marcadores a un número importante de enfermedades en humanos. En el desarrollo de vacunas se ha demostrado cómo los patógenos pueden evadir la respuesta inmune simplemente alterando la composición de las secuencias repetidas en sus genes. Existen numerosas aplicaciones informáticas destinadas a la detección de estas secuencias, no obstante éstas no cubren todas las expectativas debido a la divergencia de criterios y enfoques aplicados a la solución del problema de su detección. MIDAS implementa una solución no heurística basada en dos algoritmos combinatorios en serie: el primero detecta microsatélites exactos, y el segundo, de permitirlo los parámetros del modelo, extiende las secuencias a su versión inexacta óptima. La aplicación tiene como entrada la secuencia genómica en formato GBFF o FASTA y su salida brinda las posiciones de los microsatélites en la secuencia genómica, así como tamaños, alineamientos, flancos, posiciones, etc. El algoritmo tiene una elevada eficiencia y es exhaustivo, detectando todas las posibles secuencias repetidas independientemente de su composición nucleotídica.

Palabras clave: SSR; marcador molecular; microsatélite; minería de datos; algoritmo

ABSTRACT

Microsatellites are tandem repeat, frequent and diverse short sequences in the genomes of all species, constituting important markers in multiple areas of genomics-based research. Associations of these markers have been found in a significant number of human diseases. Vaccine development has shown how pathogens can evade the immune response by simply altering the composition of repeat sequences in their genes. There are numerous computer applications for the detection of these sequences, but they do not meet all expectations due to the divergence of criteria and approaches applied to solving the problem of their detection. MIDAS implements a non-heuristic solution based on two combinatorial algorithms in series: the first one detects exact microsatellites, and the second one, if the model parameters allow it, extends the sequences to their optimal inaccurate version. The application has as input the genomic sequence in GBFF or FASTA format and its output provides the microsatellite positions in the genomic sequence, as well as sizes, alignments, flanks and other statistics. The algorithm is highly efficient and comprehensive, detecting all possible repeat sequences regardless of their nucleotide composition.

Keywords: SSR; microsatellite; molecular marker; data mining; algorithms

Introducción

Los microsatélites son secuencias cortas repetidas en tándem (conocidas por sus acrónimos STR de short tandem repeats o SSR de simple sequence repeat, por sus siglas en inglés) con unidades de repetición entre 1 y 6 pb (algunos autores extienden su definición hasta 8 pb), que pueden constituir trectos de repeticiones que van desde algunas copias hasta cientos de éstas. Estas secuencias son abundantes en los genomas de eucariotas, asociadas fundamentalmente a regiones no codónicas, aunque no privativas de éstas. También se encuentran presentes en genomas procariotas constituyendo importantes marcadores para la genotipificación, clasificación y control epidemiológico de especies de interés ⁽¹⁾. Entre las principales motivaciones para el estudio de estas secuencias se encuentran su participación en procesos tales como la recombinación y la regulación de la transcripción ⁽²⁾, y cuando se encuentran en regiones codificantes son causa de afecciones neurodegenerativas como síndrome de frágil X, enfermedad de Huntington (HD), atrofia espinobulbar-muscular (SBMA), el síndrome de Haw River (DRPLA), las ataxias espinocerebelosas (SCA1, SCA2, SCA3, SCA6, SCA7 y SCA17), así como algunos tipos de cáncer ^(3,4). En el desarrollo de vacunas se ha demostrado cómo gérmenes patógenos pueden evadir la respuesta inmune simplemente alterando la composición de las secuencias repetidas en sus genes ⁽⁵⁾. Se ha demostrado cómo la expansión y contracción de microsatélites en bacterias puede regular la expresión de genes específicos o alterar su secuencia codificante dando como resultado variaciones antigénicas o de fase. Esto es particularmente favorable en bacterias patógenas cuando ocurre en loci de

contingencia como forma de evadir las estrategias de defensa del hospedero ^(6,7). Como marcadores genéticos han sido ampliamente usados en estudios genéticos poblacionales debido a su elevado polimorfismo consecuencia de sus altas tasas de mutación, diversidad alélica, presentar codominancia y ser selectivamente neutros. Es también muy conocida su utilización en medicina forense para la identificación de personas y grado de parentesco.

Los microsatélites han sido identificados experimentalmente a partir de librerías genómicas de organismos de interés, inspeccionando miles de clones por hibridación con sondas de microsatélites. Además de su elevado costo, estos métodos contienen el sesgo propio de la composición de patrones de secuencia preseleccionados. Con la modernización y abaratamiento de las tecnologías de secuenciación, junto a las colaboraciones para el intercambio público de secuencias como GenBank, EMBL, DDBJ entre otras, los métodos de la bioinformática han tomado la supremacía surgiendo numerosas aplicaciones que implementan algoritmos orientados a este fin. No obstante, la propia dinámica de estas secuencias, sometidas a diferentes fuerzas evolutivas, sus roles particulares, así como el interés particular de los investigadores en unas u otras en dependencia de su composición, rasgos generales y fin biológico, ha hecho que estas aplicaciones bioinformáticas implementen criterios computacionales diferentes, y por consiguiente, muestren variaciones en sus resultados ^(8,9). Por citar algunos ejemplos, encontramos aplicaciones que extienden su sistema de detección a regiones repetidas con periodicidades mayores (i.e. minisatélites y satélites); otras detectan sólo repetidos exactos o con mínimas variaciones definidas a priori; otras que emplean diccionarios preestablecidos de microsatélites o que detectan regiones de baja complejidad y luego las confirman empleando reglas establecidas. Aplicaciones como TRF, IMEx, START, SRF o TROLL ⁽¹⁰⁻¹⁴⁾ son ejemplos de software ampliamente utilizados para estos fines, e implementados con diversos criterios algorítmicos. La conclusión es que no existe una solución única, el espectro de aplicaciones se diversifica atendiendo a los tipos de SSR de interés y a los métodos computacionales empleados, haciéndose notar las diferencias en los resultados que retornan.

La aplicación que se presenta, MIDAS (Microsatellite Detection Assistant System), cumple con los siguientes principios generales: 1ro se detectan sólo microsatélites, exactos o inexactos (i.e. repetidos en tándem con patrones entre 1-8 pb, no compuestos ni complejos); 2do se detectan microsatélites exactos para luego extenderlos en caso de que sus flancos muestren alta similitud de secuencia con el patrón de repetición; 3ro la detección exacta es exhaustiva (i.e. se tienen en cuenta todos los posibles patrones que pudieran conformar un SSR); y 4to la extensión se hace por alineamiento local brindando una solución óptima de acuerdo a parámetros prefijados del alineamiento.

En la sección Métodos se describe en detalle la secuencia de pasos que sigue la aplicación, los fundamentos algorítmicos, la solución particular propuesta a los problemas de la detección inexacta de SSRs, y ejemplos de detección de SSRs exactos e inexactos.

En la sección Resultados, se expone y analiza la salida correspondiente a la detección de SSRs para el genoma de *Salmonella* entérica (subsp. entérica Seroovar Cubana str.). También se describen los parámetros y formatos de entrada y salida de la aplicación.

Métodos

El procedimiento inicia con la detección de una secuencia repetida exacta, es decir, sin sustituciones, inserciones o supresiones de bases. Para ello, en una primera etapa se implementa el autómata Aho-Crasick (AAC) que a partir de la construcción de un árbol de palabras encuentra todas las ocurrencias de éstas en un texto. En la implementación propuesta, se construye un árbol que contiene todas las palabras, de tamaños entre 1-8 nucleótidos (uno de los parámetros de la aplicación permite fijar el límite superior de este rango), formadas por combinaciones de las 4 bases nucleotídicas, y con la especificidad de que ellas mismas no constituyan secuencias repetidas (ej. aaaaa) y excluyendo las permutaciones cíclicas de ellas. ACC computa la búsqueda de estas ocurrencias eficientemente en tiempo proporcional al tamaño del texto y sin pre-procesamiento del mismo. Las ocurrencias de palabras iguales adyacentes son empalmadas y su posición registrada, estableciéndose los repetidos exactos o “semillas” de posibles repetidos inexactos. Con este paso, el algoritmo se comporta como cualquier otra aplicación que detecte repetidos exactos de forma exhaustiva y determinista (Fig. 1 (I)). Las limitaciones de los programas que detectan sólo estas secuencias son evidentes en cuanto al fin biológico que se persigue. Pensemos, solo a modo de ejemplo, en un repetido que tenga una simple modificación en una base, en cuyo caso el programa detectaría dos repetidos de la misma clase separados por una base, cuando en realidad constituían parte del mismo repetido. Este problema, que al generalizarse crea infinidad de situaciones menos triviales y complicadas de ejemplificar, constituye la principal motivación de la solución que se propone. En pocas palabras, se trata de detectar una “semilla” repetida exacta, con una cantidad de repeticiones razonable como para no ocurrir por simple azar, a partir de la cual detectar, si existiera, el repetido inexacto del cual ella forma parte. En caso de no existir dicha extensión aproximada o inexacta se reportaría el repetido exacto correspondiente, en este caso libre de ambigüedad.

La segunda etapa del algoritmo viene a solucionar el problema antes descrito. Se trata de buscar el posible candidato inexacto a partir de los flancos de la semilla exacta detectada previamente. En esta etapa se utiliza programación dinámica, es decir, el alineamiento local de la secuencia problema, incluidos los flancos, contra el patrón de repetición, empleando la eficiente técnica wraparound (WDP, Wraparound Dinamic Programming, por sus siglas en inglés) (Fig. 1(II), Fig. 2). Como es típico en los métodos de alineamiento de secuencias, la solución óptima es dependiente de los parámetros del alineamiento que definen las ponderaciones por coincidencias, sustituciones o inserciones/supresiones de bases, los cuales determinarán en última instancia el grado de conservación del microsatélite reportado.

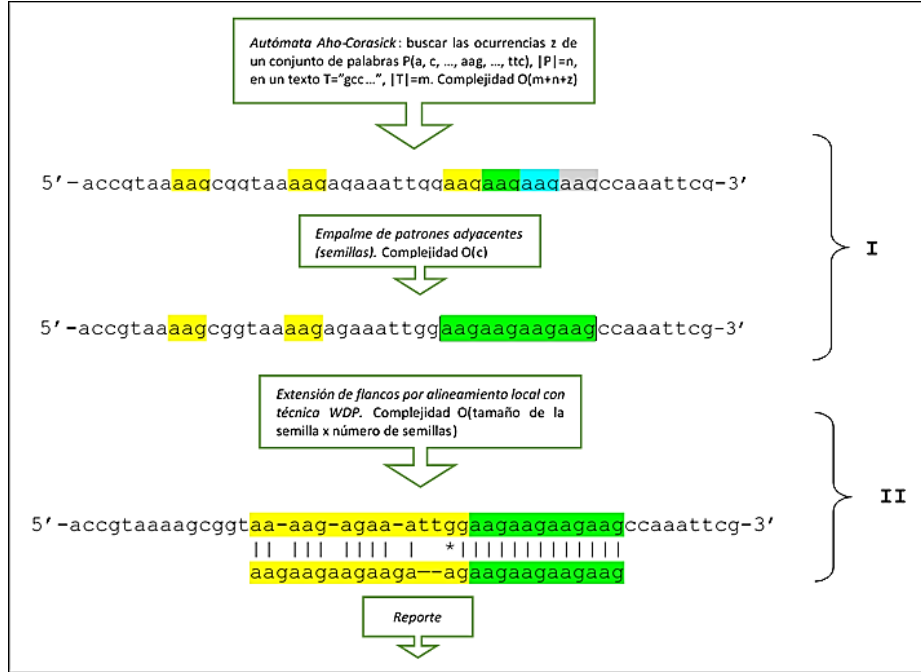


Fig. 1 - Secuencia de pasos del algoritmo implementado en MIDAS en sus dos etapas fundamentales. (I) Detección de microsatélites exactos (semillas), usando árbol de palabras (Aho-Corasick) y posterior empalme de ocurrencias. (II) Extensión de semillas y detección del posible microsatélite inexacto empleando programación dinámica.

$$\begin{aligned}
 S(i, 0) &= 0, S(0, j) = 0 \\
 S(i, j) &= \max \begin{cases} S(i-1, j-1) + \mu(c_i, c_j), \\ S(i-1, j) + \delta, \\ S(i, j-1) + \delta, \\ 0 \end{cases} \\
 \mu(c_i, c_j) &= \begin{cases} \text{match} & \text{si } c_i = c_j \\ \text{mismatch} & \text{si } c_i \neq c_j \end{cases} \\
 \delta &= \text{indel}
 \end{aligned}$$

Alineamiento Local

$$\begin{aligned}
 \text{Recálculo de fila con reinicialización de } S(i, 0): \\
 S(i, 0) &= \max \begin{cases} S(i-1, p), \\ S(i-1, 1), \\ S(i, p), \\ 0 \end{cases}
 \end{aligned}$$

Wraparound

Fig. 2 - Recurrencia que define el algoritmo de la segunda etapa en MIDAS. Es un alineamiento local clásico aplicando técnica wraparound. Basándose en la repetición del patrón, la ganancia en términos de tiempo y espacio se establece al permitir alinear la secuencia problema solo con el patrón o unidad repetida en el microsatélite. Match, mismatch (μ) e indel (δ) son los parámetros para coincidencias, sustituciones o inserción/supresión respectivamente.

Con respecto a la extensión per se hay dos problemáticas, que aparecen con poca explicitud en las aplicaciones reportadas por otros autores empleando alineamiento de secuencias, y

que deben ser aclaradas y razonablemente solucionadas: 1ro ¿hasta dónde extender en los flancos de la secuencia para reportar el alineamiento? Cuando la secuencia problema es relativamente corta el problema desaparece si utilizamos la secuencia en su totalidad para buscar la sub-secuencia repetida local óptima. En la mayoría de los casos esto no es posible, pensemos por ejemplo en un cromosoma humano de más de 200 millones de pares de bases, con miles de microsatélites candidatos en diferentes regiones del genoma. La solución que presenta MIDAS es utilizar tamaños de flancos de 3 veces el tamaño de la semilla y si el alineamiento computado cubre más del 90 por ciento de la secuencia escogida se repite el proceso de extensión de flancos y se realinea la secuencia. De esta forma garantizamos que la región a extender para buscar el repetido inexacto sea dinámica y no excluya regiones donde se pueda seguir extendiendo. 2do ¿cómo evaluar si un alineamiento es lo suficiente adecuado para decidir seleccionarlo? Este problema es inherente a todos los métodos de alineamiento de secuencia y se ha afrontado de variadas formas en dependencia del contexto. En aplicaciones para detectar repetidos, algunos autores emplean el score o puntuación del alineamiento como criterio de selección (este es el caso de TRF). Este enfoque es en cierta medida arbitrario teniendo en cuenta que el score, si bien depende de los parámetros del alineamiento, también depende del tamaño del mismo, y se establece cierto sesgo que favorece a los SSR de mayor tamaño en detrimento de los más cortos, teniendo ambos igual importancia. En el caso de MIDAS este problema desaparece teniendo en cuenta que se parte de un SSR exacto y la extensión del mismo recaerá exclusivamente en los parámetros del alineamiento, en otras palabras la aplicación no tiene la necesidad de escoger a priori un SSR estableciendo un valor de corte a partir de la puntuación del alineamiento.

Los parámetros del alineamiento son por defecto bastante restrictivos: (Match=2, Mismatch=-5, Indel=-5), aunque el usuario tiene la opción de usar otros esquemas de puntuación más relajados (4 en total) y luego podría depurar los SSRs a voluntad por inspección visual. La Figura 3 ejemplifica lo mencionado anteriormente con los resultados de la detección de dos SSR en un mismo genoma y con el mismo esquema de puntuación.

I Patrón:aag (3 pb) Posición SSR Exacto:571222 Posición Inicial SSR Inexacto:571222 Posición Final SSR Inexacto:571234 Cantidad de Coincidencias:13 Cantidad de Sustituciones:0 Cantidad de Ins/Del:0 Puntuación Alineamiento:26 <pre> gtgttagaagaaatttcccgtagaagaagaagcgggcatgacgttagg gaagaagaagaag </pre>	II Patrón:aag (3 pb) Posición SSR Exacto:951043 Posición Inicial SSR Inexacto:951030 Posición Final SSR Inexacto:951055 Cantidad de Coincidencias:23 Cantidad de Sustituciones:1 Cantidad de Ins/Del:5 Puntuación Alineamiento:28 <pre> gcccaaccgtaaaagcggtaa-aag-aga-attggaagaagaagaagccaaattcgatttg * agaagaagaaga--agaagaagaagaag </pre>
--	--

Fig. 3- Salida del programa para dos microsatélites situados en dos posiciones (separadas por 379821 pb) del genoma vibrio cholerae IEC224 (NC_016944). El patrón de secuencia es el mismo en ambos al igual que las unidades repetidas exactas (aag)⁴. La secuencia en verde es el SSR exacto, en amarillo la extensión inexacta y el resto son flancos. Los parámetros del alineamiento fueron (Match=2, Mismatch=-3, Indel=-3). En (I) el programa extendió a una guanina (g) coincidente en flanco izquierdo, sin embargo en (II) hay una extensión mucho mayor que incluyen una sustitución y cinco inserciones o supresiones de bases. Notar que esta extensión quedaría reducida a una repetición exacta en caso de emplear parámetros más restrictivos, (ej. Match=2, Mismatch=-5, Indel=-5).

Resultados y Discusión

MIDAS se presenta en su versión 1.0 (binario) para plataforma Windows 32 y 64 bits (descargar midas_v1.0.zip del material suplementario) y su código fuente está escrito totalmente en C++ STL compatible, de modo que puede ser compilado para otras plataformas (Linux, Mac OS, etc.) empleando los compiladores y librerías adecuados. Es una aplicación de consola, ideal para hacer procesamientos por lotes (batch) y encadenar a otras aplicaciones (pipelines) mediante asignación de argumentos por línea de comandos. Los argumentos de la aplicación son tres: nombre de fichero (genoma a escanear en formato FASTA o GBFF ambos de tipo simple o multi-locus), tamaño máximo de la unidad repetida a escanear y esquema de

El fichero con extensión .dat presenta en forma no tabular los datos anteriores y permite visualizar el alineamiento de secuencia. Por último, el fichero con extensión .mfaa presenta los microsatélites detectados en formato multi-fasta, en el cual la región del repetido está marcada en minúscula y los flancos en mayúscula. Este formato permite hacer procesamiento por lotes (batch) con blastn (opción de enmascaramiento explícito de sub-secuencias), para la búsqueda de candidatos polimórficos intra- e inter- especies (Fig. 4). El encabezado de este fichero presenta información como el número de acceso del GenBank, el motivo y las posiciones en el genoma.

Fig. 4 - Formato del fichero con extensión .mfaa (multi-fasta con la región repetida marcada con letra minúscula).

escaneado con MIDAS y los resultados se muestran en Fig. 5. Este genoma presenta 4,977,480 pares de bases (pb) y el tiempo de cómputo, incluida la creación de los ficheros de salida, fue menor de 3 segundos. Un total de 95 SSRs fueron detectados, 2 hexa-, 14 tetra-, 70 tri-, 7 di- y 2 mono-nucleótidos (cantidad y unidad repetida respectivamente). Los parámetros de detección fueron: unidad repetida ≤ 6 y Match=2, Mismatch=-3, Indel=-3 (esquema tipo 4 como parámetros del alineamiento para la fase de extensión). Es notable el porcentaje de SSRs con tri-nucleótidos como unidad repetida (74%), lo que hace sospechar de su localización en regiones codificantes fundamentalmente, a pesar de que en los genomas bacterianos predominan estas regiones. Los números de copia muestran un rango de 3 a 15, con media 5.8, para un coeficiente de variación de 50%, resaltando entre estos los SSRs 1 y 2 (de hexa-nucleótidos con 14 copias), 37, 75 y 76 (de tri-nucleótidos con 13, 14 y 15 copias respectivamente) y el 93 (de di-nucleótidos con 13 copias).

La entropía composicional media de los flancos 5' y 3' es de 1.86 y 1.88 respectivamente, los cuales se pueden considerar elevadas por su cercanía a 2 (valor máximo). Entre estas destaca curiosamente el flanco 3' del SSR No. 23 y el flanco 5' del SSR No. 30, ambos con entropía composicional máxima.

Accession: NC_021818.1																	
No.	Pattern	Length	Copies	Start	End	Score	Matches	Mismatches	Indel	Inaccuracy(%)	5' Flank	5'Entropy	3' Flank	3'Entropy			
1	accacg	6	14	4124875	4124962	131	79	9	0	10.2	gcagcagtggttagcgggaa	1.82	tcattggtcacatcatcgg	1.99			
2	accatg	6	14	4124875	4124963	133	80	9	0	10.1	gcagcagtggttagcgggaa	1.82	catgggtcacatcatcgg	1.97			
3	aaac	4	3	4539606	4539617	24	12	0	0	0	agaacctcttatgaaattca	1.85	tcagccttaattcttagctt	1.82			
4	aaat	4	3	1341668	1341679	24	12	0	0	0	tcaaatcgtgtatattggg	1.9	gtgagagagttatttccg	1.88			
5	acgc	4	4	1895851	1895869	28	18	1	1	10	cgatctggcgcgtctctttg	1.79	ggcgccagagagagactta	1.85			
6	agcc	4	3	163898	163910	26	13	0	0	0	gcgacgcgtaccgaagcggt	1.85	gcttaccggaattacatag	1.96			
7	agcc	4	4	2430728	2430743	27	15	1	0	6.25	aggccgaagtgccgagaat	1.85	gttcgcctgtgaacagta	1.99			
8	agcc	4	5	3149711	3149730	30	18	2	0	10	taccgttagcccgcccggtg	1.71	tcgcctgacattgctcggt	1.88			
9	agcg	4	3	2599506	2599517	24	12	0	0	0	caaagaaacccgatatgaa	1.76	gcctcgccgaggacattaa	1.94			
10	aggc	4	4	888148	888163	32	16	0	0	0	tttttctctacgttagtta	1.6	cgccgcgcgagagtgccgg	1.6			
11	cctg	4	3	1043085	1043096	24	12	0	0	0	cgcttcctgaaaaagcggtt	1.99	gaagagcgacgcttgggt	1.91			
12	cgtt	4	3	2175064	2175075	24	12	0	0	0	gcgaggctaaaaacgcttcg	1.95	ttatcggtcaggcactggct	1.95			
13	ctgg	4	4	197857	197875	33	18	1	0	5.26	ggtcgcgcaacggagcaaa	1.77	gatcgcccgagattcgacct	1.93			
14	ctgg	4	3	836393	836407	30	15	0	0	0	aatgggcggagcgtcatcgc	1.91	gacctcgctaattgttga	1.99			
15	ctgg	4	9	3751746	3751782	29	29	8	1	23.7	gtgctgacgggtatttatat	1.91	gtcgtcgcgcaacaaccac	1.85			
16	gggt	4	5	218111	218131	27	18	3	0	14.3	taaccttttgcaacgctac	1.95	agtgtatggcccgctgctt	1.88			
17	aat	3	11	3213661	3213695	30	28	7	1	22.2	cctcatgaattcttggggaa	1.99	caaaagttgcaaaataata	1.68			
18	acc	3	9	480757	480784	31	23	5	0	17.9	gaatcctccatcggtgactg	1.99	taacatttccaaaagacct	1.77			
19	acc	3	4	1138726	1138737	24	12	0	0	0	tgaccggcaccatggccaag	1.9	caactactggcgagtgag	1.94			
20	acc	3	5	4039134	4039149	27	15	1	0	6.25	tgaagctacaattcagggg	1.93	gcggggagcaggtttctcaa	1.86			
21	acc	3	4	4670518	4670530	26	13	0	0	0	cagggtcgaagcggcgcggg	1.6	gcctcgctttctgtaaaat	1.96			
22	agc	3	8	237150	237175	35	24	1	2	11.1	cagagcggattgggtctggt	1.84	gatccactattccgaatgc	1.94			
23	agc	3	10	1119681	1119712	39	27	5	0	15.6	ccatcgaccaccagcgac	1.68	cgattataaagcgtccgtc	2			
24	agc	3	4	1734328	1734340	26	13	0	0	0	gactgacgtttgagatttac	1.94	tctcgtgaggggtccgag	1.85			
25	agc	3	4	4460210	4460221	24	12	0	0	0	gcgccattgctcatgaaat	1.99	cgaaatcgccctctggagaa	1.95			
26	atc	3	4	800165	800176	24	12	0	0	0	gcgtctcctctcgcgacca	1.76	cagcggggagattcgggat	1.86			
27	atc	3	5	902834	902850	29	16	1	0	5.88	gttatgatatacttttgca	1.74	agggcatacaaatccttc	1.97			
28	atc	3	5	1615528	1615544	27	16	0	1	5.88	agcagaataccgacagaat	1.82	ggcgttaaccttccggcct	1.88			
29	atc	3	4	2479307	2479320	28	14	0	0	0	catccgtgtgctggcgagg	1.91	gcggccacagagatccga	1.78			
30	atc	3	4	3964635	3964648	28	14	0	0	0	tgtagatatgctcaccggac	2	cccagcgcaatgacacgt	1.82			
31	atg	3	6	108398	108416	28	18	1	1	10	cgctgacgtccgcatcggtc	1.85	aacgcagcttctcggggtg	1.94			
32	atg	3	4	219057	219068	24	12	0	0	0	ggcattccggtgctgctggt	1.79	tctttattgttggtgtacat	1.68			
33	atg	3	4	1557419	1557430	24	12	0	0	0	tcgcgagcccccctccaac	1.68	gcatcaccacgaataat	1.88			
34	ccg	3	4	320384	320397	28	14	0	0	0	gcgcattcaccagtagtctct	1.96	taacgattgcccgcgtgg	1.93			
35	ccg	3	6	792037	792054	31	17	1	0	5.56	ccattagcctgccaacgta	1.96	atgcattaataataccgga	1.91			
36	ccg	3	4	849993	850006	28	14	0	0	0	ggctttttccacgaccgga	1.94	ttacagataaacagggtatc	1.96			
37	ccg	3	13	917144	917184	31	33	5	4	21.4	caggcggtcaggagagactt	1.91	atcagatgaactgttggtc	1.95			
38	ccg	3	4	1354972	1354985	28	14	0	0	0	ccgcggtggcagcgcgcgag	1.58	aggatggcgaggatcggg	1.79			
39	ccg	3	4	1510859	1510870	24	12	0	0	0	gggtgatggagcgctggtcc	1.82	ggcatcggttatgctcgga	1.94			
40	ccg	3	6	2201801	2201818	36	18	0	0	0	ggcgaaaggccaaattttta	1.95	tatgaacgcgaagcgcca	1.82			
41	ccg	3	5	3026100	3026116	29	17	0	1	5.56	gaacgcctccaccaccttc	1.76	gtatgcccttccataaaat	1.9			
42	ccg	3	6	3493256	3493274	33	18	1	0	5.26	cgagactgtagtagacata	1.94	gaagggtgttagatcgcaa	1.93			
43	ccg	3	5	3745335	3745351	29	16	1	0	5.88	tgagatcgataattcatcaa	1.87	atcgagcaaacgaatgcaga	1.86			
44	ccg	3	4	3987068	3987081	28	14	0	0	0	tagatagcgcgagcttcacg	1.99	atcgggccaaacaaagcgg	1.77			
45	ccg	3	4	4151511	4151523	26	13	0	0	0	ccgatcggtcccatgccagg	1.87	tgcggaatgcagaaggttt	1.88			
46	ccg	3	5	4370073	4370087	30	15	0	0	0	tctcgtctgctgcttccag	1.72	ggaaacctgctgaccagcg	1.88			
47	ccg	3	9	4465409	4465435	39	24	3	0	11.1	caactgtgccgtcaagttca	1.99	agtgaattggctcagtaca	1.94			
48	ccg	3	7	4591653	4591674	34	20	2	0	9.09	aatactcataccaaagcga	1.74	gctcgctttacgtcttct	1.74			
49	ccg	3	4	4757355	4757367	26	13	0	0	0	gccaacctgccctgggtgtt	1.88	gaggaaaccttctgaagca	1.95			
50	ccg	3	5	4818240	4818254	30	15	0	0	0	ctgcgcgctgggttttctga	1.78	ggatgtggtttgccgatgcg	1.78			
51	ccg	3	4	4935620	4935632	26	13	0	0	0	tgcactgctgcatggcgcta	1.95	atttgcacgtccgacgcg	1.99			
52	ccg	3	6	4945192	4945211	30	18	2	0	10	cccgtcgccggaagcacag	1.74	aaagggcattcgttcacc	1.96			
53	cct	3	9	480759	480785	39	24	3	0	11.1	atctccatcggtgactgca	1.96	aacatttccaaagacctg	1.85			
54	cgg	3	5	237802	237816	30	15	0	0	0	tcgcgcgccaaccggcgaa	1.72	aaatgaccaaatggtttaa	1.78			
55	cgg	3	5	436672	436686	25	14	1	0	6.67	cgctatcggttccagataat	1.99	agagcagtgccatcaggtc	1.94			
56	cgg	3	4	493840	493852	26	13	0	0	0	ttcaaacgtcagcgtttcca	1.95	agtgaattgtagctcagca	1.95			
57	cgg	3	4	506644	506656	26	13	0	0	0	gataggaatagcagaagga	1.58	aaagtcccccaaatagt	1.87			
58	cgg	3	6	778415	778432	29	17	0	1	5.56	tgacctcttcacggatgac	1.96	atagtgcgcgcatgctgg	1.96			
59	cgg	3	11	1399278	1399310	31	27	6	1	20.6	aagaacgcatttgatgagcc	1.96	atctgtcgatgttcggtca	1.93			
60	cgg	3	4	1420189	1420200	24	12	0	0	0	gtcgccgaagccctggaac	1.85	gaagatgccataaacctgt	1.91			
61	cgg	3	5	1543714	1543729	27	15	1	0	6.25	cggtgataatgctgtgatt	1.86	ttagcggtccgctgctgac	1.9			
62	cgg	3	6	1598682	1598701	25	17	3	0	15	tcgcgcatggccgggattgt	1.82	acctggcattcgtatggc	1.95			
63	cgg	3	10	1698496	1698527	34	27	5	1	18.2	gcgtatgacgtactgattgt	1.93	tctactcgcgcgcaaggc	1.93			
64	cgg	3	5	1828708	1828722	25	14	1	0	6.67	gagcatatagaggcttctgc	1.99	ttccgctatgacgcggtga	1.95			

Fig. 5 - Resultados de la detección de SSRs en el genoma de Salmonella enterica (subsp. enterica Serovar Cubana str., código de acceso NC_021818). Esta representación es la que muestra el fichero de salida con extensión .xls.

65	cgg	3	4	1898266	1898278	26	13	0	0	0	agcggcttgcgcctgtctga	1.88	ctgggctatcttctatgc	1.86
66	cgg	3	4	2477755	2477766	24	12	0	0	0	tccgatcagccgaaccgct	1.91	aatgcttacgctgcggcg	1.93
67	cgg	3	4	2888933	2888945	26	13	0	0	0	tggtgtttcagcaaatcttc	1.86	aattgtaataatagccctg	1.87
68	cgg	3	4	3883088	3883099	24	12	0	0	0	attctgggtgtgcggtcata	1.91	gatggccggtgcggtccgc	1.65
69	cgg	3	4	3929160	3929172	26	13	0	0	0	cgaacaacagaaacccagac	1.44	aaaccacgcgacccgctag	1.77
70	cgg	3	4	4727117	4727130	28	14	0	0	0	gccatgatgtcgtgatcat	1.99	cattcaagcaggtgctggc	1.99
71	cgg	3	4	4786486	4786497	24	12	0	0	0	cgggaagccgagcaggaaac	1.56	agaccagtccccccagcgcc	1.72
72	cgt	3	4	749920	749931	24	12	0	0	0	aatacggcgccactaccggc	1.86	accggctgctggacacgct	1.88
73	cgt	3	5	3347418	3347432	25	14	1	0	6.67	gacttaacaatccgcccag	1.88	ggcgctgggtgcacacgaa	1.96
74	cgt	3	5	3602816	3602832	29	17	0	1	5.56	ccgaacagtttatcgataaa	1.91	catcacgcgaaaccctata	1.8
75	ctg	3	14	360753	360794	54	36	6	0	14.3	acaggctgcgtttgagccca	1.97	tagcgtttgctggcgtttgt	1.68
76	ctg	3	15	424437	424482	42	36	10	0	21.7	aagaaaaattcggtgtttcc	1.93	aagaaaaactgaattcgac	1.71
77	ctg	3	4	1101330	1101342	26	13	0	0	0	tgatccgacggtattcgag	1.99	gtagcagcgtatccagacg	1.95
78	ctg	3	4	1391866	1391877	24	12	0	0	0	tcctggcaggcgaggataaa	1.94	accgatcagaaggattatt	1.96
79	ctg	3	10	1845945	1845976	34	26	6	0	18.8	tggcgaggccagggcattca	1.86	gcgattgcgaaaaagttcga	1.93
80	ctg	3	6	1965950	1965968	28	17	2	0	10.5	atccgcatgtgattaccgg	1.96	tttgcgcgtcgggtcatgc	1.79
81	ctg	3	4	2822605	2822617	26	13	0	0	0	agcgtcgtgaagaagaagc	1.8	aagtgaagaagcactcgt	1.93
82	ctg	3	4	3247298	3247309	24	12	0	0	0	tactggcgatgatcatgcgc	1.99	gcgtcaatctcggtggt	1.88
83	ctt	3	5	226114	226129	27	15	1	0	6.25	gaagacggactgcatacca	1.94	gaagatgcggaagatcatgc	1.88
84	ggt	3	4	198817	198830	28	14	0	0	0	atccatgaacggcagacgc	1.88	ataaactcacctatcgggc	1.97
85	ggt	3	4	3696472	3696483	24	12	0	0	0	gttgccacggcagggtcacc	1.88	tggcgtgattttgataccga	1.93
86	ggt	3	4	3742603	3742615	26	13	0	0	0	ggaccgccagggtttgtg	1.86	acaactgagcgtgcggaac	1.88
87	cg	2	6	1227443	1227455	26	13	0	0	0	ggcgccagggcgataattt	1.96	tcgtcggttaagtaacgc	1.99
88	cg	2	6	1532556	1532568	26	13	0	0	0	caggcgccgctgaccgtggt	1.78	gaaaaactgggtattatcc	1.91
89	cg	2	6	2255344	2255355	24	12	0	0	0	caactggcagacgcttatgc	1.99	aatcgacgccgcagctat	1.94
90	cg	2	6	3019348	3019359	24	12	0	0	0	gacgaagatgaagcgtttgc	1.93	taactacgtcgtaaatgac	1.95
91	cg	2	8	4109832	4109847	27	16	0	1	5.88	accgctatcttacgcctgt	1.87	ttccgcatcggtatttgcg	1.88
92	cg	2	6	4111111	4111123	26	13	0	0	0	agctatcacctaaccgcaa	1.8	tggcacagcaggcaacggaa	1.78
93	cg	2	13	4540368	4540393	35	24	1	2	11.1	tgaagatatcagctgctgc	1.99	gtatcgctatttccgcag	1.95
94	a	1	11	3004616	3004626	22	11	0	0	0	agcgtcggttttcttttc	1.68	tccattaaatacaaatgtt	1.8
95	t	1	10	170557	170566	20	10	0	0	0	tccttagcatctgctaagga	1.99	gcctaaaattacctgattat	1.86

Fig. 5 - (cont.). Resultados de la detección de SSRs en el genoma de *Salmonella enterica* (subsp. *enterica* Serovar Cubana str., código de acceso NC_021818). Esta representación es la que muestra el fichero de salida con extensión .xls.

Conclusiones

Se presenta la aplicación MIDAS para la detección de microsatélites (SSRs) exactos e inexactos. El algoritmo es totalmente combinatorio y tiene dos etapas o procedimientos generales: 1ra detección de SSRs exactos por técnica de reconocimiento de patrones de texto exactos y 2da extensión de los mismos mediante técnica de programación dinámica. Se muestran los resultados, y un breve análisis, de la detección de estas secuencias en el genoma de *Salmonella enterica* (subsp. *enterica* Serovar Cubana). La aplicación es eficiente e intuitiva, presentando tiempos de ejecución bajos (4,977,480 pb en 3 seg.) y una cantidad mínima de parámetros de entrada lo cual lo hace más asequible para el usuario. Presenta formatos de salida descriptivos, tabulados y bioinformáticos que permiten una fácil y muy completa visualización para el análisis de los resultados, permitiendo también el encadenamiento de éstos con otras aplicaciones, por ejemplo para extracción de rasgos anotados en otros repositorios o detección de polimorfismos mediante búsquedas extensivas de tipo BLAST.

Referencias

1. Liang S, Watanabe H, Terajima J, Li C, Liao J, Tung S, Chiou C. Multilocus Variable-Number Tandem-Repeat Analysis for Molecular Typing of *Shigella sonnei*. *JOURNAL OF CLINICAL MICROBIOLOGY* Nov 2007;45(11):3574–80.
2. Martin P, Makepeace K, Hill S, Hood D, Moxon E. Microsat instability regulates transcription factor binding and gene expression. *Proc Natl Acad Sci USA*. 2005; 102(10):3800-4.
3. Mitas M. Trinucleotide repeats associated with human disease. *Nucleic Acids Res*. 1997;25(12):2245-54.
4. Arzimanoglou I, Gilbert F, Barber H. Microsatellite instability in human solid tumors. *Cancer* 1998;82(10):1808-20.
5. Moxon ER, Rainey PB, Nowak MA, Lenski RE. Adaptive evolution of highly mutable loci in pathogenic bacteria. *Current Biology*. 1994;4:24-33.
6. Moxon R, Bayliss C, Hood D. Bacterial contingency loci: the role of simple sequence DNA repeats in bacterial adaptation. *Annu. Rev. Genet.* 2006;40:307–333.
7. Bayliss CD, Field D, Moxon ER. The simple sequence contingency loci of *Haemophilus influenzae* and *Neisseria meningitidis*. *J. Clin. Invest.* 2007;107:657–662.
8. Grover A, Aishwarya V, Sharma PC. Searching microsatellites in DNA sequences: approaches used and tools developed. *Physiol Mol Biol Plants* 2012 Jan–Mar; 18(1):11–19.
9. Leclercq S, Rivals E, Jarne P. Detecting microsatellites within genomes: significant variation among algorithms. *BMC Bioinformatics*. 2007;8:125.
10. Benson G. Tandem repeats finder: a program to analyze DNA sequences. *Nucleic Acids Res*. 1999;27:573–580.
11. Mudunuri SB, Nagarajaram HA. IMEx: Imperfect Microsatellite Extractor. *Bioinformatics*. 2007;23:1181–1187.
12. Merkel A, Gemmell N. Detecting short tandem repeats from genome data: opening the software black box. *Brief Bioinform.* 2008;9:355–366.
13. Zhou H, Du L, Yan H. Detection of tandem repeats in DNA sequences based on parametric spectral estimation. *IEEE Trans Inf Technol Biomed*. 2009;13:747–755.
14. Castelo AT, Martins W, Gao GR. TROLL: Tandem repeats occurrence locator. *Bioinformatics*. 2002; 18:634–636.

MIDAS: Computer application for the identification of exact and inaccurate microsatellites in genomic sequences.

MIDAS: Aplicación informática para la identificación de microsatélites exactos e inexactos en secuencias genómicas.

Carlos M. Martínez Ortiz ^{1*}

¹Department of Biochemistry, ICPB "Victoria de Girón", University of Medical Science, La Habana, Cuba

* email address: cmmo@infomed.sld.cu

ABSTRACT

Microsatellites are tandem repeat, frequent and diverse short sequences in the genomes of all species, constituting important markers in multiple areas of genomics-based research. Associations of these markers have been found in a significant number of human diseases. Vaccine development has shown how pathogens can evade the immune response by simply altering the composition of repeat sequences in their genes. There are numerous computer applications for the detection of these sequences, but they do not meet all expectations due to the divergence of criteria and approaches applied to solving the problem of their detection. MIDAS implements a non-heuristic solution based on two combinatorial algorithms in series: the first one detects exact microsatellites, and the second one, if the model parameters allow it, extends the sequences to their optimal inaccurate version. The application has as input the genomic sequence in GBFF or FASTA format and its output provides the microsatellite positions in the genomic sequence, as well as sizes, alignments, flanks and other statistics. The algorithm is highly efficient and comprehensive, detecting all possible repeat sequences regardless of their nucleotide composition.

Keywords: SSR; microsatellite; molecular marker; data mining; algorithms

RESUMEN

Los microsatélites son secuencias cortas repetidas en tándem, frecuentes y diversas en los genomas de todas las especies, constituyendo importantes marcadores en múltiples áreas de investigación basadas en la genómica. Se han encontrado asociaciones de estos marcadores a un número importante de enfermedades en humanos. En el desarrollo de vacunas se ha demostrado cómo los patógenos pueden evadir la respuesta inmune simplemente alterando la composición de las secuencias repetidas en sus genes. Existen numerosas aplicaciones informáticas destinadas a la detección de estas secuencias, no obstante éstas no cubren todas las expectativas

debido a la divergencia de criterios y enfoques aplicados a la solución del problema de su detección. MIDAS implementa una solución no heurística basada en dos algoritmos combinatorios en serie: el primero detecta microsatélites exactos, y el segundo, de permitirlo los parámetros del modelo, extiende las secuencias a su versión inexacta óptima. La aplicación tiene como entrada la secuencia genómica en formato GBFF o FASTA y su salida brinda las posiciones de los microsatélites en la secuencia genómica, así como tamaños, alineamientos, flancos, posiciones, etc. El algoritmo tiene una elevada eficiencia y es exhaustivo, detectando todas las posibles secuencias repetidas independientemente de su composición nucleotídica.

Palabras Clave: SSR, microsatélite, marcador molecular, minería de datos, algoritmo.

Introduction

Microsatellites are short tandem repeat sequences (known by their acronyms STR for short tandem repeats or SSR for simple sequence repeat) with repetition units between 1 and 6 bps (some authors extend their definition up to 8 bps), which can be tracts of repetitions ranging from a few copies to hundreds of copies. These sequences are abundant in the eukaryotic genomes, mainly associated with, but not exclusive, to non-coding regions. They are also present in prokaryotes genomes, constituting important markers for the genotyping, classification and epidemiological control of species of interest ⁽¹⁾. Among the main motivations for the study of these sequences are their participation in processes such as recombination and transcription regulation ⁽²⁾, and when found in coding regions they cause neurodegenerative conditions such as fragile X syndrome, Huntington's disease (HD), spinobulbar-muscular atrophy (SBMA), Haw River syndrome (DRPLA), spinocerebellar ataxias (SCA1, SCA2, SCA3, SCA6, SCA7, and SCA17), as well as some types of cancer ^(3,4). Vaccine development has shown how pathogens can evade the immune response by simply altering the composition of repeat sequences in their genes ⁽⁵⁾. It has been proved how microsatellite expansion and contraction in bacteria can regulate expression of specific genes or affect its coding sequence resulting in phase or antigenic variation. This is particularly advantageous in pathogenic bacteria at contingency loci, as a way to evade the defense strategies of its host ^(6,7). As genetic markers they have been widely used in genetic population studies due to their high polymorphism as a consequence of their high mutation rates, allelic diversity, co-dominance and being selectively neutral. Its use in forensic medicine for the identification of persons and degree of kinship is also well known.

The microsatellites have been experimentally identified from genomic libraries of organisms of interest, inspecting thousands of clones by hybridization with microsatellite probes. In addition to their high cost, these methods contain the bias inherent in the composition of pre-selected sequence patterns. With the modernization and lower cost of sequencing technologies, along with collaborations for the public exchange of sequences such as GenBank, EMBL, DDBJ, among others, bioinformatics methods have taken supremacy, giving rise to numerous applications that implement algorithms oriented to this end. However, the very dynamics of these sequences, subjected to different evolutionary forces, their particular roles, as well as the particular interest of researchers in one or the other depending on their composition, general features and biological purpose, has led these bioinformatics applications to implement different computational criteria, and consequently, to show variations in their results ^(8,9). To cite a few examples, we find applications that extend their detection system to repeat regions with longer periodicities (i.e. minisatellites and satellites); others detect only exact repeats or with minimal variations defined a priori; others use preset dictionaries of microsatellites or detect regions of low complexity and then confirm those using established rules. Applications such as TRF, IMEx, START, SRF or TROLL ^(10, 11, 12, 13, 14) are examples of software widely used for mining these kind of sequences, implemented with different algorithmic criteria. The conclusion is that there is not a unique solution, the spectrum of applications is diversified according to the types of SSR of interest and the computational methods used, being reflected in result's differences.

The application we present, MIDAS (Microsatellite Detection Assistant System), fulfills with the following general principles: 1st only exact or inaccurate microsatellites are detected (i.e. not composite nor complex tandem repeats with patterns between 1-8 bp); 2nd exact microsatellites are detected and then extended if their flanks show a high sequence similarity with the repetition pattern; 3st the exact detection is exhaustive (i.e. all possible patterns that could make up an SSR are taken into account); and 4th extension is done by local alignment providing an optimal solution according to pre-determined alignment parameters.

The following section, Methods, describes in detail the sequence of steps followed by the application, algorithmic fundamentals, particular solution proposed to the problems of inaccurate detection of SSRs, and examples of detection of exact and inaccurate SSRs. It also describes the parameters and input - output formats of the application.

In the Results section, it is exhibited and analyzed the outputs corresponding to the detection of SSRs for *Salmonella enterica* (subsp. *enterica* Serovar *Cubana*). The input parameters and output formats of the application are described too.

Methods

The procedure starts with the detection of an exact repeat sequence, i.e. without substitutions, insertions or deletions of bases. For this purpose, the Aho-Crasick automaton (ACA) is implemented in the first stage, which finds all the occurrences of words in a text from the construction of a word tree. In the proposed implementation, a tree is constructed that contains all the words, of sizes between 1-8 nucleotides (one of the parameters of the application allows setting the upper limit of this range), formed by combinations of the 4 nucleotide bases, and with the specificity that they do not themselves constitute repeat sequences (e.g. aaaaaa) and excluding its cyclic permutations. ACA computes the search for these occurrences efficiently in time proportional to the size of the text and without pre-processing it. The occurrences of adjacent identical words are spliced and their position recorded, establishing the exact repeats or "seeds" of possible inaccurate repeats. With this step, the algorithm behaves like any other application that detects exact repetitions in an exhaustive and deterministic way (Fig. 1 (I)). The limitations of programs that detect only these sequences are obvious in terms of the biological purpose pursued. Let's think, just as an example, of a repeat that has a simple modification in a base, in which case the program would detect two repeats of the same class separated by a base, when in fact they were part of the same repeat. The generalized version of this problem creates an infinite number of situations that are less trivial and complicated to exemplify, and constitutes the main motivation for the proposed solution. In short, it is a matter of detecting an exact repeat "seed", with a reasonable number of repetitions not occurring by mere chance, from which to detect, if it exist, the inaccurate repeat one of which it is part. If there is no such approximate or inaccurate extension, the corresponding exact repetition will be reported, in this case free of ambiguity.

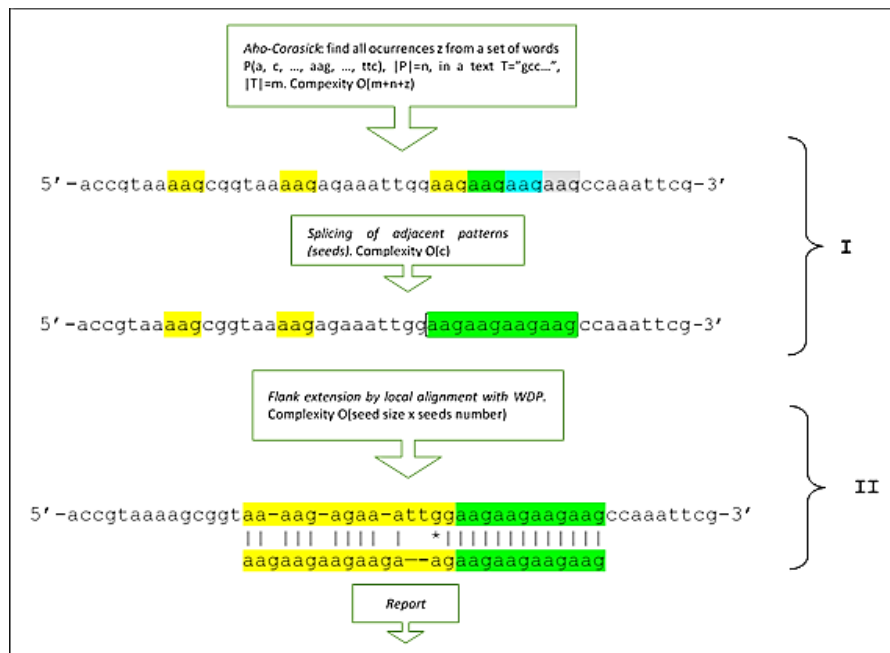


Fig. 1- Sequence of steps of the algorithm implemented in MIDAS in its two fundamental stages. (I) Detection of exact microsatellites (seeds), using word tree (Aho-Corasick) and subsequent splicing of occurrences. (II) Seed extension and detection of possible inaccurate microsatellite using dynamic programming.

The second stage of the algorithm solves the problem described above. The aim is to search for the possible inaccurate candidate from the flanks of the exact seed previously detected. Dynamic programming, i.e. the local alignment of the problem sequence, including flanks, against the repetition pattern, is used at this stage using the efficient wraparound technique (WDP, wraparound dynamic programming) (Fig. 1(II), Fig. 2). As is typical in sequence alignment methods, the optimal solution is dependent on the alignment parameters that define the weightings by coincidence, substitution or insertion/deletion of bases, which will ultimately determine the degree of conservation of the reported microsatellite.

$$\begin{array}{l}
S(i, 0) = 0, S(0, j) = 0 \\
\\
S(i, j) = \max \begin{cases} S(i-1, j-1) + \mu(c_i, c_j), \\ S(i-1, j) + \delta, \\ S(i-1, j) + \delta, \\ 0 \end{cases} \\
\\
\mu(c_i, c_j) = \begin{cases} \text{match si } c_i = c_j \\ \text{missmatch si } c_i \neq c_j \\ \delta = \text{indel} \end{cases} \\
\\
\text{Row recalculation, initialization of } S(i, 0): \\
\\
S(i, 0) = \max \begin{cases} S(i-1, p), \\ S(i-1, 1), \\ S(i, p), \\ 0 \end{cases}
\end{array}$$

Local Alignment

Wraparound

Fig. 2. Recurrence that defines the algorithm of the second stage in MIDAS. It is a classic local alignment applying wraparound technique. Based on the repetition of the pattern, the gain in terms of time and space is established by allowing to align the problem sequence only with the pattern of the microsatellite. Match, mismatch (μ) and indel (δ) are the parameters for matches, substitutions or insertion/deletion respectively.

With respect to the extension per se there are two problems, which appear little explicit in the applications reported by other authors using sequence alignment, and which must be clarified and reasonably solved: 1st, how far do we extend on the flanks of sequence to report the alignment? When the sequence under study is relatively short the problem disappears if we use the all the sequence to find the optimal local repeat subsequence. In most cases this is not possible, think for example of a human chromosome with 200 million of base pairs, and thousands of candidate microsatellites in different regions of the genome. The solution presented by MIDAS is to use flank sizes of 3 times the seed size, and if the computed alignment covers more than 90 percent of the chosen sequence, the flank extension process is repeated and the sequence is realigned. In this way, we guarantee that the region to be extended to look for the inaccurate repeat is dynamic and does not exclude regions where it can continue to be extended. 2nd, How to evaluate if an alignment is adequate to decide to select it? This problem is inherent to all methods of sequence alignment and has been addressed in a variety of ways depending on the context. In applications for tandem repeats, some authors use the alignment score as selection criteria (this is the case of TRF). This approach is somewhat arbitrary, bearing in mind that while the score depends on the parameters of alignment, it also depends on the size of the alignment, and a certain bias is established that favors larger SSRs over shorter ones, being both equally important. In the case of MIDAS this problem disappears taking into account that the starting point is an exact SSR and the extension of the same will fall exclusively on the alignment parameters, in other words the application does not have the need to choose a priori an SSR establishing a cut-off value from the alignment score.

The alignment parameters are by default quite restrictive (Match=2, Mismatch=-5, Indel=-5), although the user has the option of using other more relaxed scoring schemes (4 in total) and then could debug SSRs at will by visual inspection. Figure 3 exemplifies the above with the results of the detection of two SSR in the same genome and with the same scoring scheme.



Fig. 3- Output of the program for two microsatellites located in two positions (separated by 379821 bp) of the genome vibrio cholerae IEC224 (NC_016944). The sequence pattern is the same in both as well as the number of exact repeat units (aag)₄. The sequence in green is the exact SSR, in yellow the inaccurate extension and the rest are flanks. The alignment parameters were (Match=2, Mismatch=-3, Indel=-3). In (I) the program extended to a guanine (g) coincident in left flank, however in (II) there is a much greater extension that includes a substitution and five insertions or deletions of bases. Note that this extension would be reduced to an exact repetition if more restrictive parameters were used, (e.g. Match=2, Mismatch=-5, Indel=-5).

Results and Discussion

MIDAS is presented in its version 1.0 (binary) for Windows 32 and 64 bits platform (download v1.0.zip of the supplementary material) and its source code is written entirely in C++ STL compatible, so that it can be compiled for other platforms (Linux, Mac OS, etc.) using the appropriate compilers and libraries. It is a shell application, ideal for batch processing and linking to other applications (pipelines) by command line argument assignment. The application's arguments are three: 1th file name (genome to be scanned in FASTA or GBFF format, both single or multi-locus), 2nd maximum size of the repeat unit to be scanned and 3rd alignment parameter scheme

for match, mismatch and indel, 4 in total, (2,-7,-7) (2,-5,-5,-7) (2,-5,-5) (2,-3,-5). As output, MIDAS returns three text files named equal the input file and with extensions .xls, .dat and .mfaa (the.xls could open directly with Excel or another spreadsheet application). The .xls file (Fig. 5) is in tabular format and its columns are: Pattern, Length (period), Start (initial position in the genome), End (final position in the genome), Score (alignment score), Matches (matching bases), Mismatches (non-matching bases), Indel (insertions and deletions of bases), Inaccuracy (% of inaccuracy of the repeat, measurement of imperfection of the repeat), 5' Flank (flank sequence to the 5' end), 5' Entropy (compositional entropy in 5' flank), 3' Flank (flank sequence to the 3' end), 3' Entropy (compositional entropy in 3' flank). Some developers of software for tandem repeats detection report the compositional entropy of the repeat region, this being obvious and mostly low. What allows a microsatellite to be used as a genetic marker is the variations in the number of copies and the uniqueness of flanks for its amplification in PCR techniques. MIDAS reports the entropy of the flanks, being these candidates for primer design in PCR technique, and giving a measure of how informative and unique they may be in the genome.

The file with .dat extension presents the previous data in a non-tabular form and allows the sequence alignment to be displayed. Finally, the file with extension .mfaa presents the detected microsatellites in multi-fasta format, with the repeat region marked in lower case and the flanks in upper case. This format allows batch processing with blastn (in Filter and Masking Options, mask lowercase letters checkbox), for the search of intra- and inter-species polymorphic candidates (Fig. 4). The header of this file presents information such as the GenBank access number, the pattern and the positions in the genome.

```
>NC_021818.1 |accag[4124875-4124962]
GCAGCAGTGGCTAGCGGAAaccaccatcagccatgaccatgaccagaccagaccagaccagaccatgaccatgaccatgaccatgaccatCATGGTCACATACATCCGG
>NC_021818.1 |accatg[4124875-4124963]
GCAGCAGTGGCTAGCGGAAaccaccatcagccatgaccatgaccagaccagaccagaccagaccatgaccatgaccatgaccatgaccatCATGGTCACATACATCCGGA
>NC_021818.1 |aaac[4539606-4539617]
AGAACCTCTTATGAATTCaaacaaacaaacTCAGCCTTAATCTTATGCTT
>NC_021818.1 |aaat[1341668-1341679]
TCAAACCTGGTGATATATGGGaaataaataaatGTGAGAGAGTTATATTTCCG
>NC_021818.1 |acgc[1895851-1895869]
CGATCTGGCGCTCTCTTTGacgcacaacgcagcagcgcGGCGCCAGGAGAGAGACTTA
>NC_021818.1 |agcc[163898-163910]
GCGACGCGTACCGAAGCGGTcagccagccagccGCTTACCGGAATTAACATAG
>NC_021818.1 |agcc[2430728-2430743]
AGGCCGAAGGTGCCGAGAAtagccagccagccatccGTTCCGCTGGTAACGAGTA
>NC_021818.1 |agcc[3149711-3149730]
TACCGGTAGCCCCCGCGGcagccagccagccggcagcTCGCCTGACATTGTCGCGTT
>NC_021818.1 |agc[2599506-2599517]
CAAAGAAACGCCGATATGAAagcagcagcagcGCTCGCCAGGACATTAA
```

Fig. 4-File format with extension .mfaa (multi-fasta with repeat region marked with lowercase letter).

The genome of *Salmonella enterica* (subsp. *enterica* Serovar *Cubana* str., access code NC_02181818) taken from the NCBI repository (<https://www.ncbi.nlm.nih.gov/>), was scanned with MIDAS and the results are shown above (Fig. 5). This genome has 4.977.480 base pairs and the computation time, including the creation of the output files, was less than 3 seconds. A total of 95 SSRs were detected, 2 hexa-, 14 tetra-, 70 tri-, 7 di- and 2 mono-nucleotides (number and repeat unit respectively) The detection parameters were: repeat unit <=6 and Match=2, Mismatch=-3, Indel=-3 (type 4 scheme of alignment parameters for the extension phase). The percentage of SSRs with tri-nucleotides (74%) is notable, which makes it suspicious of their location in coding regions, despite the fact that these regions predominate in bacterial genomes. The

copy numbers show a range of 3 to 15, with an average of 5.8, for a coefficient of variation of 50%, highlighting among these the SSRs numbers 1 and 2 (hexa-nucleotides with 14 copies), 37, 75 and 76 (of tri-nucleotides with 13, 14 and 15 copies respectively) and 93 (of di-nucleotides with 13 copies).

Accession: NC_021818.1														
No.	Pattern	Length	Copies	Start	End	Score	Matches	Mismatches	Indel	Inaccuracy(%)	5' Flank	5'Entropy	3' Flank	3'Entropy
1	accacg	6	14	4124875	4124962	131	79	9	0	10.2	gcagcagtgctagcgggaa	1.82	tcatggtcacatcatccgg	1.99
2	accatg	6	14	4124875	4124963	133	80	9	0	10.1	gcagcagtgctagcgggaa	1.82	catggtcacatcatccgga	1.97
3	aaac	4	3	4539606	4539617	24	12	0	0	0	agaacctctatgaataatca	1.85	tacagcttaattctatgctt	1.82
4	aaat	4	3	1341668	1341679	24	12	0	0	0	tcaaaactggtgatataatgg	1.9	gtgagagagttatattccg	1.88
5	agc	4	4	1895851	1895869	28	18	1	1	10	cgatctggcgctctcttgg	1.79	ggcgccaggagagactta	1.85
6	agcc	4	3	163898	163910	26	13	0	0	0	gcagcgcgtacggaagcggt	1.85	gcttacgggaatcaacatag	1.96
7	agcc	4	4	2430728	2430743	27	15	1	0	6.25	agagccgaaggtgccgagaat	1.85	gttccgcttgtaacagagta	1.99
8	agcc	4	5	3149711	3149730	30	18	2	0	10	taccggtagcccccgcgcgg	1.71	tcgcctgaactgtcgctt	1.88
9	agcg	4	3	2599506	2599517	24	12	0	0	0	caaaagaaacgcgatatgaa	1.76	gcctcgccaggacattaa	1.94
10	agcg	4	4	888148	888163	32	16	0	0	0	ttttttcttacgttattga	1.6	cgccgcgcgaagtgccgg	1.6
11	cctg	4	3	1043085	1043096	24	12	0	0	0	cgcttctgaaaaagcgttc	1.99	gaagagcgacgtttgtctgt	1.91
12	cgtt	4	3	2175064	2175075	24	12	0	0	0	gcagagctaaaaacgcttcg	1.95	ttatcggtcagcactggct	1.95
13	ctgg	4	4	197857	197875	33	18	1	0	5.26	ggctggcgcaacggagcaaa	1.77	gatgcgccggatctgacct	1.93
14	ctgg	4	3	836393	836407	30	15	0	0	0	aatggcgaggagctgtatcgc	1.91	gaacctgctatattgtgca	1.99
15	ctgg	4	9	3751746	3751782	29	29	8	1	23.7	gtctgaacggtatttatat	1.91	gtctgcgcacaaacacac	1.85
16	ggtt	4	5	218111	218131	27	18	3	0	14.3	taaccttttgcaacgctac	1.95	agtgtatggccgcgtggt	1.88
17	aat	3	11	3213661	3213695	30	28	7	1	22.2	cccatgaattcttgaggaa	1.99	caaaaagtgcgaataataa	1.68
18	acc	3	9	480757	480784	31	23	5	0	17.9	gaatctccatcggtgactg	1.99	taacatttccacaaagacct	1.77
19	acc	3	4	1138726	1138737	24	12	0	0	0	tgaccggcaccaatggcaag	1.9	caactactggcgcatggag	1.94
20	acc	3	5	4039134	4039149	27	15	1	0	6.25	tgaagctacaattcaggagg	1.93	gcggggagcaggttctgcaa	1.86
21	acc	3	4	4670518	4670530	26	13	0	0	0	cagggtcaagcggcgccggg	1.6	gcctcgcttctgttaaat	1.96
22	agc	3	8	237150	237175	35	24	1	2	11.1	cagagcggaattgggtctggt	1.84	gatccactattccgaatgc	1.94
23	agc	3	10	1119681	1119712	39	27	5	0	15.6	ccatcgaccaccagcgcaac	1.68	cgatttaataaggctctcgtc	2
24	agc	3	4	1734328	1734340	26	13	0	0	0	gaactgacgtttgagatttac	1.94	tctcgctgagggctcgacg	1.85
25	agc	3	4	4460210	4460221	24	12	0	0	0	gcgcatttgcctcatgaaat	1.99	cgaatcgccctctggagaa	1.95
26	atc	3	4	800165	800176	24	12	0	0	0	gcgtctcctctcgcgacca	1.76	cagcggggagattccggat	1.86
27	atc	3	5	902834	902850	29	16	1	0	5.88	gttatgatatacttttgca	1.74	agggcatcaacaagctcttc	1.97
28	atc	3	5	1615528	1615544	27	16	0	1	5.88	agcagaatacggagcagaat	1.82	ggccgttaactcttcggcct	1.88
29	atc	3	4	2479307	2479320	28	14	0	0	0	catccgatgtgctggcgagg	1.91	gccgccacagagagatccga	1.78
30	atc	3	4	3964635	3964648	28	14	0	0	0	tgtagatatactgacacggac	2	ccacgagccagatagcacgt	1.82
31	atg	3	6	108398	108416	28	18	1	1	10	cgctgaacgtcgcatcggtc	1.85	aacgagctgttccgggttg	1.94
32	atg	3	4	219057	219068	24	12	0	0	0	ggcattccggtgcttcggtt	1.79	tcttatgttggtgtacat	1.68
33	atg	3	4	1557419	1557430	24	12	0	0	0	tccgagcccccctgccaac	1.68	gcgatacccaagcaaatatt	1.88
34	ccg	3	4	320384	320397	28	14	0	0	0	gcgcattcacagtagtcttc	1.96	taacgatgtgcgcgcctgg	1.93
35	ccg	3	6	792037	792054	31	17	1	0	5.56	ccattaggcttcccaacgta	1.96	atgccatataataccgga	1.91
36	ccg	3	4	849993	850006	28	14	0	0	0	ggcttttccacgaccgca	1.94	ttacagataaccaggtgatc	1.96
37	ccg	3	13	917144	917184	31	33	5	4	21.4	caggcgctcaggagagattg	1.91	atcagatgaactgttgatc	1.95
38	ccg	3	4	1354972	1354985	28	14	0	0	0	ccgcggtggcagcgccgac	1.58	aggtatggcgaggatgcgg	1.79
39	ccg	3	4	1510859	1510870	24	12	0	0	0	ggtagtggagcgctgtctc	1.82	ggcattggctatcgtcggat	1.94
40	ccg	3	6	2201801	2201818	36	18	0	0	0	ggcgaagcgcaaattttta	1.95	tatgaacgcgaagacggca	1.82
41	ccg	3	5	3026100	3026116	29	17	0	1	5.56	gaacgccttccacacatttc	1.76	gtatgcccttcatcaaat	1.9
42	ccg	3	6	3493256	3493274	33	18	1	0	5.26	cgacagctgagtagacata	1.94	gaaggtgttcagatcgga	1.93
43	ccg	3	5	3745335	3745351	29	16	1	0	5.88	ttagatcgataattcatcaa	1.87	atcgacgaacgaatcgaga	1.86
44	ccg	3	4	3987068	3987081	28	14	0	0	0	tagatagcgcgagcttcaac	1.99	atcgggcccaacaaagcg	1.77
45	ccg	3	4	4151511	4151523	26	13	0	0	0	ccgatcggtccatgccagg	1.87	tgcggaaatgcagaaggttt	1.88
46	ccg	3	5	4370073	4370087	30	15	0	0	0	tctccgtctgctgttccag	1.72	ggaaacctgctgaccagcg	1.88
47	ccg	3	9	4465409	4465435	39	24	3	0	11.1	caactgtccgtcaagttca	1.99	agtgaattgctcagtagca	1.94
48	ccg	3	7	4591653	4591674	34	20	2	0	9.09	aatactcataccaaagcga	1.74	gtcgcgtttacgtcttct	1.74
49	ccg	3	4	4757355	4757367	26	13	0	0	0	gccaaactgccctgggtgtt	1.88	gaggaaaccttctgaagca	1.95
50	ccg	3	5	4818240	4818254	30	15	0	0	0	ctgcgcctggttttctga	1.78	ggatgtggtttgccatgcg	1.78
51	ccg	3	4	4935620	4935632	26	13	0	0	0	tgcactgcgtcatggcgcta	1.95	attttgatactccgacgcg	1.99
52	ccg	3	6	4945192	4945211	30	18	2	0	10	ccgctcgccgcaagcacaag	1.74	aaaggccattccgttacc	1.96
53	cct	3	9	480759	480785	39	24	3	0	11.1	atcctccatcggtgactgca	1.96	aaactttccacaagaactg	1.85
54	cgg	3	5	237802	237816	30	15	0	0	0	tccgcgcgcaacgcgcaaac	1.72	aaatgaccaatgtttta	1.78
55	cgg	3	5	436672	436686	25	14	1	0	6.67	cgctatcggttccagataat	1.99	agagcagtgccatcagctg	1.94
56	cgg	3	4	493840	493852	26	13	0	0	0	ttcaaagctcagacgttcca	1.95	agtgaatttgtagctcagca	1.95
57	cgg	3	4	506644	506656	26	13	0	0	0	gatagggaatagcagaagaag	1.58	aaagtgcgcccaaatagt	1.87
58	cgg	3	6	778415	778432	29	17	0	1	5.56	tgacctcttcacggatgac	1.96	atagtcagcgcatgacgg	1.96
59	cgg	3	11	1399278	1399310	31	27	6	1	20.6	aagaacgcatttgatgagcc	1.96	atctggtcgatgttcggtca	1.93
60	cgg	3	4	1420189	1420200	24	12	0	0	0	gtcgccgaagccctggaac	1.85	gaagatgccaataaaccgt	1.91
61	cgg	3	5	1543714	1543729	27	15	1	0	6.25	cggtgatgaatgctgtgatt	1.86	ttagcggtccgctgctgatc	1.9
62	cgg	3	6	1598682	1598701	25	17	3	0	15	tcggcgatggccgggttgt	1.82	acctggcgattcgtatggc	1.95
63	cgg	3	10	1698496	1698527	34	27	5	1	18.2	gcgtatgacgtactgattgt	1.93	tctactcgcgccgaagggc	1.93
64	cgg	3	5	1828708	1828722	25	14	1	0	6.67	gagcatagagaggttctgc	1.99	ttcgctatcgacgggtga	1.95

Fig. 5- Results of the detection of SSRs in the genome of *Salmonella enterica* (subsp. *enterica*Serovar *Cubana* str., access code NC_021818). This representation is the one shown in the output file with .xls extension.

65	cgg	3	4	1898266	1898278	26	13	0	0	0	agcggcttgcctgtctga	1.88	ctggctatcttctatcgc	1.86
66	cgg	3	4	2477755	2477766	24	12	0	0	0	tccgatcagccgaaccgct	1.91	aatgcgttacgctgcggcg	1.93
67	cgg	3	4	2888933	2888945	26	13	0	0	0	tgtgtttcagcaaatcttc	1.86	aattgtaataatagccctg	1.87
68	cgg	3	4	3883088	3883099	24	12	0	0	0	attctggttgcctgcata	1.91	gatggcgggtgcgggtccgc	1.65
69	cgg	3	4	3929160	3929172	26	13	0	0	0	cgaacaacagaaacgcagaa	1.44	aaacacgcgacgcgcgtag	1.77
70	cgg	3	4	4727117	4727130	28	14	0	0	0	gccatgatgctgctgatcat	1.99	cattcaagcaggtgctggtc	1.99
71	cgg	3	4	4786486	4786497	24	12	0	0	0	cgggaagccgagcaggaac	1.56	agaccagtcgccgacgcgc	1.72
72	cgt	3	4	749920	749931	24	12	0	0	0	aatacggcgccactaccggc	1.86	accggctggctggacacgt	1.88
73	cgt	3	5	3347418	3347432	25	14	1	0	6.67	gacttaacaatccgccag	1.88	ggcgtggttgcatcacgaa	1.96
74	cgt	3	5	3602816	3602832	29	17	0	1	5.56	cgaacagtttatcgataaa	1.91	catcaccggaacccatata	1.8
75	ctg	3	14	360753	360794	54	36	6	0	14.3	acaggctgcgtttgagccca	1.97	tagcgtttgtggcgttgtt	1.68
76	ctg	3	15	424437	424482	42	36	10	0	21.7	aagaaaaattcgggtttcc	1.93	aagaaaaactgaattcgac	1.71
77	ctg	3	4	1101330	1101342	26	13	0	0	0	tgatcccgacggtattcgag	1.99	gtacgcagctatccagacg	1.95
78	ctg	3	4	1391866	1391877	24	12	0	0	0	tcctggcaggcgcgataaa	1.94	accgatcagcaaggattatt	1.96
79	ctg	3	10	1845945	1845976	34	26	6	0	18.8	tggcgacggccagccatca	1.86	gcgattgcgaaaaattcga	1.93
80	ctg	3	6	1965950	1965968	28	17	2	0	10.5	atgccggtatgtattaccg	1.96	tttgcgcctcgctcatgc	1.79
81	ctg	3	4	2822605	2822617	26	13	0	0	0	agcgtcgtgaagaagaagc	1.8	aagtggagaacgcactcgt	1.93
82	ctg	3	4	3247298	3247309	24	12	0	0	0	tactggcgatgatcatgcgc	1.99	gcgtcaatctgtgctggt	1.88
83	ctt	3	5	226114	226129	27	15	1	0	6.25	gaagacggactcatatcca	1.94	gaagatgcggaagatcatgc	1.88
84	ggt	3	4	198817	198830	28	14	0	0	0	atccatgaacggcagacgc	1.88	ataaactcacctatgcgggc	1.97
85	ggt	3	4	3696472	3696483	24	12	0	0	0	gttccacggcagggtcacc	1.88	tggcgtgattttgatccga	1.93
86	ggt	3	4	3742603	3742615	26	13	0	0	0	ggaccgcaggggtttgtg	1.86	acaacgtgacgtgcggaac	1.88
87	cg	2	6	1227443	1227455	26	13	0	0	0	ggcgccgagggcgataatt	1.96	tcgtcggttaagtcatgc	1.99
88	cg	2	6	1532556	1532568	26	13	0	0	0	caggcgcgctgacgtggt	1.78	gaaaaactgggtattatcc	1.91
89	cg	2	6	2255344	2255355	24	12	0	0	0	caactggcagcgttatgc	1.99	aatgcagcccgagcatat	1.94
90	cg	2	6	3019348	3019359	24	12	0	0	0	gacgaagatgaagcgttgc	1.93	taactacgtcgtcaattgc	1.95
91	cg	2	8	4109832	4109847	27	16	0	1	5.88	accgctatcttacgctgt	1.87	ttccgcatcggtatttgcg	1.88
92	cg	2	6	4111111	4111123	26	13	0	0	0	agctatcacctaaccgcaa	1.8	tggcacagcagcaacggaa	1.78
93	cg	2	13	4540368	4540393	35	24	1	2	11.1	tgaagatcagctctgctgc	1.99	gtatcggtatttccgcag	1.95
94	a	1	11	3004616	3004626	22	11	0	0	0	agcgtcggtttttcttttc	1.68	tccattaaatacaagtggt	1.8
95	t	1	10	170557	170566	20	10	0	0	0	tccttagcatctgctaagga	1.99	gcctaaataacctgattat	1.86

Fig. 5- (cont.) Results of the detection of SSRs in the genome of *Salmonella enterica* (subsp. *enterica* Serovar *Cubana* str., access code NC_021818). This representation is the one shown in the output file with .xls extension.

The average compositional entropy of the 5' and 3' flanks is 1.86 and 1.88 respectively, which can be considered high due to their proximity to 2 (maximum value). Among these, the most outstanding are 3' flank of SSR No. 23 and 5' flank of SSR No. 30, both with maximum compositional entropy.

Conclusions

In this paper we present MIDAS, an application for detection of accurate and inaccurate microsatellites (SSRs). The algorithm is fully combinatorial and has two general stages or procedures: 1st detection of exact SSRs by the technique of exact text patterns recognition and 2nd extension of them by means of dynamic programming technique. The result, and a brief analysis, of these sequences in the genome of *Salmonella enterica* (subsp. *enterica* Serovar *Cubana*) are shown. The application is efficient and intuitive, featuring low runtimes (processing 4,977,480 bp in 3 sec.) and a minimum number of input parameters which makes it more users friendly. It presents descriptive, tabulated and bioinformatic output formats that allow an easy and very complete visualization for the analysis of the results, also allowing the linking of these with other applications, for example extraction of annotated features in GenBank or detection of polymorphisms through extensive BLAST database searches.

References

1. Liang S, Watanabe H, Terajima J, Li C, Liao J, Tung S, Chiou C. Multilocus Variable-Number Tandem-Repeat Analysis for Molecular Typing of *Shigella sonnei*. *JOURNAL OF CLINICAL MICROBIOLOGY* Nov 2007;45(11):3574–80.
2. Martin P, Makepeace K, Hill S, Hood D, Moxon E. Microsat instability regulates transcription factor binding and gene expression. *Proc Natl Acad Sci USA*. 2005; 102(10):3800-4.
3. Mitas M. Trinucleotide repeats associated with human disease. *Nucleic Acids Res*. 1997;25(12):2245-54.
4. Arzimanoglou I, Gilbert F, Barber H. Microsatellite instability in human solid tumors. *Cancer* 1998;82(10):1808-20.
5. Moxon ER, Rainey PB, Nowak MA, Lenski RE. Adaptive evolution of highly mutable loci in pathogenic bacteria. *Current Biology*. 1994;4:24-33.
6. Moxon R, Bayliss C, Hood D. Bacterial contingency loci: the role of simple sequence DNA repeats in bacterial adaptation. *Annu. Rev. Genet.* 2006;40:307–333.
7. Bayliss CD, Field D, Moxon ER. The simple sequence contingency loci of *Haemophilus influenzae* and *Neisseria meningitidis*. *J. Clin. Invest.* 2007;107:657–662.
8. Grover A, Aishwarya V, Sharma PC. Searching microsatellites in DNA sequences: approaches used and tools developed. *Physiol Mol Biol Plants* 2012 Jan–Mar; 18(1):11–19.
9. Leclercq S, Rivals E, Jarne P. Detecting microsatellites within genomes: significant variation among algorithms. *BMC Bioinformatics*. 2007;8:125.
10. Benson G. Tandem repeats finder: a program to analyze DNA sequences. *Nucleic Acids Res*. 1999;27:573–580.
11. Mudunuri SB, Nagarajaram HA. IMEx: Imperfect Microsatellite Extractor. *Bioinformatics*. 2007;23:1181–1187.
12. Merkel A, Gemmell N. Detecting short tandem repeats from genome data: opening the software black box. *Brief Bioinform.* 2008;9:355–366.
13. Zhou H, Du L, Yan H. Detection of tandem repeats in DNA sequences based on parametric spectral estimation. *IEEE Trans Inf Technol Biomed.* 2009;13:747–755.
14. Castelo AT, Martins W, Gao GR. TROLL: Tandem repeats occurrence locator. *Bioinformatics*. 2002; 18:634–636.